

Eberhard Karls Universität Tübingen

Geographisches Institut

Masterarbeit

**Eignung von Fernerkundungsdaten zur Ableitung des
flächendeckenden Wärmebedarfs von Wohngebäuden
in Baden - Württemberg**

Betreuer:

Prof. Dr. Volker Hochschild

(Geographisches Institut der Universität Tübingen)

Dr. Michael Wurm

(Deutsches Zentrum für Luft- und Raumfahrt (DLR), Deutsches
Fernerkundungsdatenzentrum (DFD))

Vorgelegt am 30.05.2018

von

Stefan Borngraeber

Abgabe der Masterarbeit

Hiermit versichere ich, Stefan Borngraeber, dass

- ich diese Arbeit selbstständig verfasst habe
- diese Arbeit keine anderen, als die angegebenen Quellen benutzt und ich alle wörtlich oder sinngemäß aus anderen Werken übernommenen Aussagen als solche gekennzeichnet habe
- diese Arbeit weder vollständig, noch in wesentlichen Teilen Gegenstand eines anderen Prüfungsverfahrens war.

Datum,

Unterschrift

Inhaltsverzeichnis

Abbildungsverzeichnis	4
Tabellenverzeichnis	5
1. Übergreifende Einführung	7
1.1. Fernerkundung im Wärmesektor	7
1.2. Kommunale Wärmeplanung in Deutschland – ein Überblick.....	8
1.3. Bisheriger Entwicklungsstand der Wärmeplanung	11
1.4. Wärmeplanung und Fernerkundung – eine Gegenüberstellung.....	12
1.5. Zielsetzung der vorliegenden Arbeit	14
2. Genutzte Daten.....	15
3. Klassifikation der Landbedeckung	23
3.1. Methodik.....	23
3.1.1. Vorprozessierung der Sentinel-2 – Daten	23
3.1.2. Ableitung von Texturen.....	25
3.1.3. Klassifikator	26
3.1.4. Phase 1 – Klassifikation des Testgebietes	32
3.1.4.1. Klassenschema und Sampling.....	32
3.1.4.2. Variationen der Klassifikation.....	34
3.1.5. Phase 1 – Ergebnisse	36
3.1.6. Schlussfolgerungen für die Gesamtszene	43
3.2. Phase 2 – Klassifikation der Gesamtszene	44
3.2.1. Klassenschema und Sampling.....	44
3.2.2. Phase 2 – Ergebnisse	46

3.2.3.	Phase 2 – Abschätzung der Genauigkeit	57
4.	Klassifikation des Wärmebedarfs für Wohngebäude	61
4.1.	Methodik zur Klassifikation der Gebäudetypen	61
4.1.1.	Aufbereitung der Gebäudedaten	62
4.1.2.	Einbindung der Landbedeckungsklassifikation	63
4.1.3.	Berechnung weiterer Gebäudemerkmale.....	64
4.2.	Klassifikation der Gebäudetypen	66
4.2.1.	Klassenschema und Sampling.....	66
4.2.2.	Ergebnisse der Klassifikation	68
4.3.	Ableiten der Wärmebedarfswerte	83
4.3.1.	Konzept.....	83
4.3.2.	Ergebnisse.....	86
5.	Zusammenfassende Betrachtung.....	90
6.	Diskussion und Ausblick.....	92
7.	Literaturverzeichnis	96
Anhang.....		101
A1 –	Detaillierte Beschreibung der weiteren Varianten zur Klassifikation der Landbedeckung	102
A2 –	Darstellungen der Gebäudeanzahl je Gebäudetyp pro Verwaltungsebene	107
A3 –	Konzept zur Ableitung des Wärmebedarfs von Wohngebäuden – Tabellen.....	112

Abbildungsverzeichnis

Abbildung 1: Übersicht verschiedener zu erhebender Informationen	9
Abbildung 2: Anteile verschiedener Heizsysteme von Wohngebäuden in Deutschland	10
Abbildung 3: Räumliche und spektrale Auflösung von Sentinel-2	16
Abbildung 4: Prozessierung bis Level-1C.....	17
Abbildung 5: Übersicht der hier genutzten Sentinel-2 Szenen	18
Abbildung 6: Klassen des CORINE2012 1ha – Produkts	19
Abbildung 7: Übersicht der verschiedenen Detail – Stufen	21
Abbildung 8: Beispieltyp für Einfamilienhaus	22
Abbildung 9: Beispiel für Sanierungspakete.....	23
Abbildung 10: Workflow der Level-2A – Korrektur	24
Abbildung 11: Effekt der Atmosphärenkorrektur	25
Abbildung 12: Schematische Beschreibung von Random Forest.....	27
Abbildung 13: Testgebiet Heilbronn	31
Abbildung 14: Balanced Accuracy – Varianten 1 bis 4	37
Abbildung 15: TPR – Varianten 1 bis 4	38
Abbildung 16: TNR - Varianten 1 bis 4.....	39
Abbildung 17: Balanced Accuracy - Varianten 5 bis 9	40
Abbildung 18: TPR - Varianten 5 bis 9	41
Abbildung 19: TNR - Varianten 5 bis 9.....	42
Abbildung 20: Anzahl der Training - Samples pro Klasse	45
Abbildung 21: Mittlere Flächengrößen der Training - Samples pro Klasse	46
Abbildung 22: Abbildung 23: Klassifikation der Landbedeckung - Übersicht	48
Abbildung 23: Flächenanteile der Klassen pro Gemeinde	49
Abbildung 24: Statistische Verteilung der Flächenanteile auf Gemeindeebene	51
Abbildung 25: Flächenanteile der Klassen pro Gemeinde	53

Abbildung 26: Statistische Verteilung der Flächenanteile auf Landkreisebene.....	54
Abbildung 27: Flächenanteile der Klassen pro Gemeinde	56
Abbildung 28: Statistische Verteilung der Flächenanteile auf Landkreisebene.....	57
Abbildung 29: Verteilung der Klassen auf Samples zur Validierung	58
Abbildung 30: mittlere Fläche der Referenz - Polygone	59
Abbildung 31: TPR, TNR und Balanced Accuracy für Gesamtszene	60
Abbildung 32: TPR - Klassifikationsansatz 1	69
Abbildung 33: TNR - Klassifikationsansatz 1.....	70
Abbildung 34: TPR - Klassifikationsansatz 2	72
Abbildung 35: TNR - Klassifikationsansatz 2.....	73
Abbildung 36: TPR - Klassifikationsansatz 3	75
Abbildung 37: TNR - Klassifikationsansatz 3.....	76
Abbildung 38: Flächenanteile der Landbedeckungsklassen pro Gebäudeklasse.....	77
Abbildung 39: TPR und TNR - Klassifikationsansatz 4	80
Abbildung 40: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene in Baden - Württemberg	81
Abbildung 41: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene in Baden - Württemberg – Räumliche Verteilungsmuste	82
Abbildung 42: Wärmebedarfswerte auf Gebäudeebene am Beispiel Tübingen. Ergebnisse des vierten Klassifikationsansatzes	87
Abbildung 43: Mittlerer Wärmebedarf pro Verwaltungseinheit	89

Tabellenverzeichnis

Tabelle 1: Klassenschema des LBM-DE 2015	20
Tabelle 2: Initiales Klassenschema	33
Tabelle 3: Referenzdaten und Sampling	33
Tabelle 4: Varianten 1 bis 4.....	34
Tabelle 5: Varianten 5 bis 9.....	35

Tabelle 6: Schema einer Konfusionsmatrix	36
Tabelle 7: Konfusionsmatrix - Variante 4	42
Tabelle 8: Samples für Gesamtszene.....	44
Tabelle 9: Gegenüberstellung von relativen und absoluten Flächenanteilen.....	55
Tabelle 10: Konfusionsmatrix für Gesamtszene.....	59
Tabelle 11: Klassenschema für Gebäudetypen	66
Tabelle 12: Sampling für Gebäudetypen.....	67
Tabelle 13: Übersicht über die Klassifikationsansätze	68
Tabelle 14: Konfusionsmatrix - Klassifikationsansatz 1.....	71
Tabelle 15: Konfusionsmatrix - Klassifikationsansatz 2.....	74
Tabelle 16: Konfusionsmatrix - Klassifikationsansatz 3.....	79
Tabelle 17: Konfusionsmatrix - Klassifikationsansatz 4.....	81
Tabelle 18: Schema des Konzeptes zur Ableitung des Wärmebedarfs am Beispiel der EFH / Teil A....	83
Tabelle 19: Schema des Konzeptes zur Ableitung des Wärmebedarfs am Beispiel der EFH / Teil B....	84
Tabelle 20: Wärmebedarfswerte pro Gebäudetyp	85

1. Übergreifende Einführung

Die vorliegende Arbeit befasst sich mit der Einbettung von Datenprodukten, sowie Methoden der Fernerkundung in den Kontext kommunaler Wärmeplanung. Um die Zielsetzung der Arbeit ableiten zu können, sollen in diesem Kapitel zunächst die Möglichkeiten beschrieben werden, die der Fernerkundung als wissenschaftliche Disziplin im Bereich des Wärmesektors zugesprochen werden. Im Folgenden werden die Grundlagen der kommunalen Wärmeplanung erläutert. Anschließend erfolgt eine Gegenüberstellung zwischen den Anforderungen der Planung einerseits und den Möglichkeiten, bzw. dem Potenzial von Fernerkundung als unterstützende Komponente andererseits.

1.1. Fernerkundung im Wärmesektor

Der Einsatz von Fernerkundung, insbesondere von satellitengestützten Sensoren zur Erforschung relevanter Parameter hinsichtlich des Wärmebedarfs, kann vereinfachend in zwei Bereiche gegliedert werden:

Zum einen die direkte Messung von Strahlung im thermalen Bereich des elektromagnetischen Spektrums (Weng 2009; Bechtel, Zakšek, und Hoshyaripour 2012; Weng und Fu 2014; Bechtel 2015). Auf diese Weise lassen sich nicht nur urbane Phänomene, wie beispielsweise Wärmeinseln, detektieren, sondern es ist ebenfalls möglich, die gemessenen Werte in Bezug zu setzen zu den vorherrschenden Gebäude-, oder auch Siedlungstypen. Somit kann auf die jeweilige Energieeffizienz, und damit auf etwaigen erhöhten Wärmeenergiebedarf bestimmter Gebäude rückgeschlossen werden. Ein mitunter wesentlicher Nachteil dieser direkten Messungen besteht aufgrund der meist vergleichsweise geringen räumlichen Auflösung der jeweiligen Sensoren. So weist beispielsweise Landsat-8 im thermalen Bereich lediglich eine Auflösung von 100m x 100m auf (USGS 2016), was jedoch zur diskreten Klassifikation von Gebäuden zu gering ist.

Zum anderen besteht die Möglichkeit, Datenprodukte der Fernerkundung zur indirekten Bestimmung des Wärmebedarfs heranzuziehen. Hierbei im Zentrum steht die Kombination verschiedener Informationen, wie beispielsweise Geiß et al. (2011) beschreiben. Stellvertretend für weitere Studien wird hier beschrieben, wie die Kombination aus satellitengestützten Sensoren, sowie die GIS – basierte Verknüpfung weiterer

Daten zur Herleitung von Wärmebedarfswerten herangezogen werden kann. Der wesentliche Merkmalsunterschied zur direkten Messung bezieht sich auf die Tatsache, dass im Kontext solcher Studien nicht zwangsläufig direkte Messwerte zur abgestrahlten Energie von Gebäuden vorliegen. Beispiele indirekter Indikatoren werden u.a. von Sen (2004), sowie von Lu (2006) beschrieben. So betrachtet die letztgenannte Studie die Möglichkeit, via Fernerkundung die im Untersuchungsgebiet vorhandene Biomasse abzuschätzen. Diese Information kann in weiteren Studien genutzt werden, um im Sinne der (kommunalen) Wärmeplanung die Machbarkeit verschiedener Versorgungsstrategien zu evaluieren. Ebenfalls von Relevanz sind beispielsweise Informationen zur Höhe der jeweils betrachteten Objekte, welche auf Basis eines digitalen Oberflächenmodells ermittelt werden und der Charakterisierung der physischen Eigenschaften von Gebäuden dienen (Geiß et al. 2011; Walde et al. 2013; Wurm, Schmitt, und Taubenböck 2016). Ebenso werden spektrale Informationen außerhalb des thermalen Bereiches genutzt, um u.a. Landbedeckungsklassen differenzieren zu können. Mittels einer solchen Klassifikation lassen sich die verschiedenen Nutzungsklassen mit dazugehörigen Bedarfswerten verknüpfen.

1.2. Kommunale Wärmeplanung in Deutschland – ein Überblick

Kommunale Wärmeplanung kann im Allgemeinen als ein Instrument gesehen werden, das im Kontext der Energiewende in Deutschland (Nitsch 2008) im Sinne der Reduktion des Energieverbrauchs zu Wärmezwecken eingesetzt werden soll (SH-MLUR 2014; UMBW 2014; FVEE 2015; Gochermann 2016; Schubert 2016). Weiterhin soll mittels dieses Instrumentariums eine Möglichkeit geschaffen werden, einen im ökonomischen Sinne wirtschaftlichen Umgang mit Wärmeenergie zu realisieren (Maier 2016). Nach Orth (2016) ist das zugrundeliegende Konzept informeller Natur. Es weist also keinen formal bindenden Charakter gegenüber den Kommunen auf, sondern kann vielmehr als eine Hilfe zur Planung verstanden werden, aufgrund derer eine langfristige Strategie zur Wärmeenergienutzung entwickelt werden kann. Die Entwicklung eines Wärmeplans kann nach Maier (2016) und (Orth 2016) in die folgenden Arbeitsschritte gegliedert werden:

1. Eine Bestandsaufnahme der bestehenden Strukturen, sowie eine entsprechende Bedarfsermittlung mit folgender Analyse des vorhandenen Potenzials.

Hierbei gilt es in einem ersten Ansatz, die bestehenden Gebäudestrukturen hinsichtlich ihrer physischen Beschaffenheit, ebenso wie ihres jeweiligen Baualters zu erfassen und abzubilden. Daraufhin folgt eine Betrachtung der vorhandenen Verteilernetze, ebenso wie der ansässigen Energieversorger. Im Fokus steht dabei die Zentralität der jeweiligen Versorgungsstrategie, d.h. die Unterscheidung zwischen zentraler Versorgung durch einzelne Erzeugungsanlagen und dezentraler Versorgung. Um nun eine Gegenüberstellung von Angebot und Nachfrage zu ermöglichen (siehe Abbildung 1), erfolgt in einem dritten Ansatz die Evaluierung der im betrachteten Gebiet vorhandenen Energiepotenziale. Hier gemeint sind beispielsweise nicht genutzte Wälder, oder auch landwirtschaftliche Nebenprodukte, welche zur Energie-, bzw. Wärmegewinnung genutzt werden können.

Abbildung 1 zeigt eine zusammenfassende Übersicht über jene Daten und Informationen, welche im Rahmen des ersten Planungsschrittes zu erheben sind.

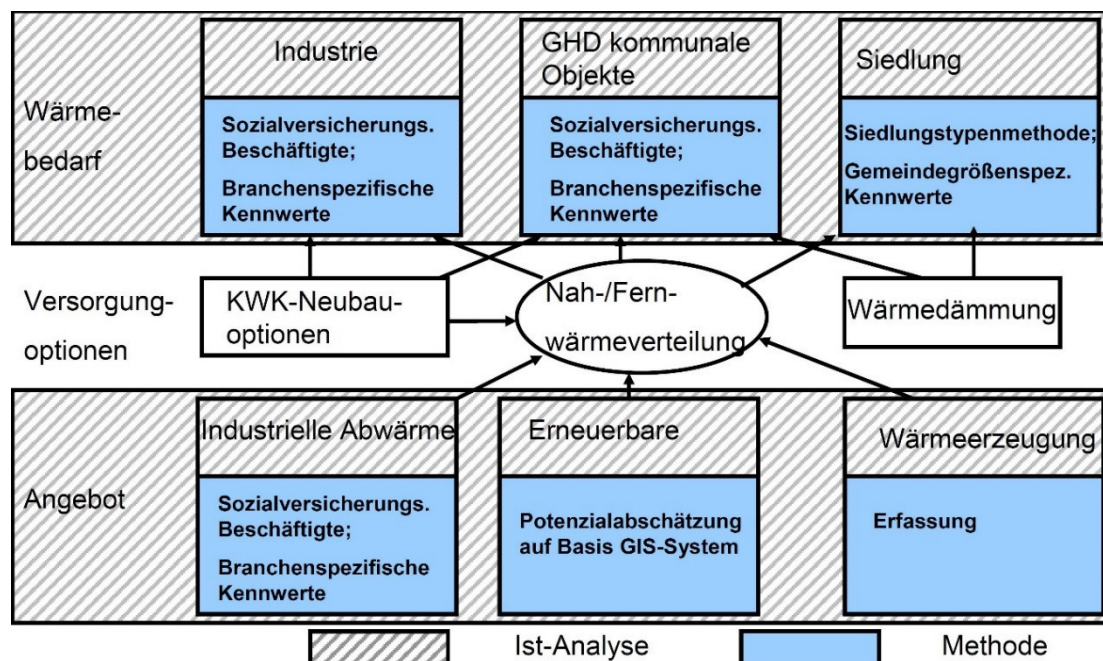


Abbildung 1: Übersicht verschiedener zu erhebender Informationen; Quelle: Blesl et al. 2009: 8

2. In einem zweiten Schritt werden die bisher zusammengetragenen Informationen genutzt, um erste Konzepte zu einer optimierten Energieversorgung zu entwickeln. Bei dieser Entwicklung stehen, zusätzlich zu den Fragen nach energetischer Gebäudesanierung, jene nach Energieträgern, ebenso wie nach einer möglichen Erweiterung bestehender Versorgungsnetze im Blickpunkt. Das

Konzept soll dem Zweck dienen, die zukünftige Versorgung mit Wärmeenergie möglichst umweltfreundlich, sowie ökonomisch sinnvoll zu planen. Ökonomisch sinnvoll meint hier nach Maier (2016) eine Steigerung der regionalen Wertschöpfung, beispielsweise aufgrund einer gesteigerten Nutzung von Fernwärme, welche wiederum von regional ansässigen Anbietern zur Verfügung gestellt wird. Ideal wäre hierbei ein möglichst hoher Anteil erneuerbarer Energieträger.




Abbildung 2: Anteile verschiedener Heizsysteme von Wohngebäuden in Deutschland; Quelle: Maier 2016: 5

Wie in Abbildung 2 ersichtlich, stellt sich die Verteilung der verschiedenen Heizsysteme in Deutschland (Stand 2015) überaus einseitig, zugunsten von Zentralheizungen dar. Mittels einer Wärmeplanung auf kommunaler Ebene soll diese Verteilung nun dahingehend verändert werden, dass, basierend auf den oben genannten Analysen, deutlich mehr Gebäude über Fernwärme versorgt werden. Die weitgehende Unabhängigkeit von fossilen Energieträgern, ebenso wie die angesprochene regionale Wertschöpfung, werden hierfür als Argumente herangezogen (Maier 2016).

Die Schritte 3 und 4 umfassen unter Bezugnahme auf die durchgeführten Arbeitsschritte 1 und 2 den finalen Entwurf eines Konzeptes, sowie die anschließende Umsetzung.

Die vorliegende Arbeit befasst sich im Kern mit dem nach Maier (2016) ersten Arbeitsschritt, wobei der Fokus hier explizit auf der Analyse der Bestandsgebäude liegt. Wie

oben bereits ansatzweise beschrieben, umfasst die Bestandsanalyse von Gebäuden, bzw. deren wärmerelevanten Eigenschaften innerhalb eines Gebietes eine Vielzahl unterschiedlicher räumlicher und thematischer Parameter, welche u.a. in Loga et al. (2015) beschrieben werden. Dies sind im Wesentlichen:

- Welche Nutzung weisen Gebäude auf?
- Welches Alter weisen die Gebäude auf?
- Welche baulichen Merkmale weisen die Gebäude auf?
- Wurde eine energetische Sanierung der Gebäude durchgeführt?
- Gibt es in der Umgebung Flächen, welche zur Produktion, bzw. zum Anbau von energetisch verwertbaren Stoffen genutzt werden können?
- Wie lässt sich die Siedlungsstruktur eines Gebietes beschreiben?

Definiert man ein Gebäude als räumliche Entität, so können all diese Parameter als Attribute übergeben werden. Durch eine Verknüpfung dieser ist es dann möglich, Rückschlüsse auf den jeweiligen Bedarf an Wärmeenergie zu ziehen. Eine solche Verknüpfung kann im Zuge der weiteren Arbeitsschritte als Datengrundlage für folgende Überlegungen und Diskussionen herangezogen werden, wie beispielsweise in Kelm et al. (2014) und Schubert (2016).

Das hier betrachtete Gebiet umfasst die Gesamtfläche von Baden – Württemberg. Hinsichtlich der entsprechenden Gebäude wurde mit Blick auf den technischen, sowie zeitlichen Rahmen der Arbeit folgende Einschränkung festgelegt: die zu untersuchenden Gebäude entsprechen jenen mit Wohnnutzung. Eine detaillierte Beschreibung der Selektion dieses Nutzungstyps erfolgt in den nächsten Kapiteln.

1.3. Bisheriger Entwicklungsstand der Wärmeplanung

Während in Deutschland der kommunalen Wärmeplanung bisher, wie oben bereits angedeutet, lediglich empfehlender, und keineswegs bindender Charakter zugewiesen ist, so wird dieses Planungskonzept in anderen Ländern bereits landesweit umgesetzt. Als beispielhaft hierfür kann Dänemark genannt werden (Chittum und Østergaard

2014; ENS 2017). Aber auch Schottland verfügt bereits über landesweite Datensätze zur Beschreibung des jeweiligen Wärmebedarfs (Seaton 2015). In beiden Fällen umfassen die entsprechenden Daten nicht nur Informationen zum Wärmebedarf der Gebäude, sondern ebenfalls weitreichende und flächendeckende Informationen zur jeweiligen Netzinfrastruktur. Mit Blick auf Deutschland fehlt bisher ein solch flächendeckender und einheitlicher Datensatz mit direkt nutzbaren Informationen zum Wärmebedarf von Gebäuden. Dennoch gibt es auch hier Bestrebungen, Richtwerte hinsichtlich des Energiebedarfs auf Basis von Musterhäusern bereitzustellen (Loga et al. 2015). Diese wurden beispielsweise seitens der Landesanstalt für Umwelt Baden – Württemberg (LUBW) genutzt, um unter anderem Wärmebedarfswerte für Gebäude in ganz Baden – Württemberg bereitzustellen (Blesl et al. 2009). Zweierlei bleibt hier jedoch anzumerken: zum einen basieren die Bedarfswerte auf genannten Musterhäusern, was wiederum einen erheblichen Grad an Generalisierung hinsichtlich konkreter Bedarfswerte nach sich zieht. Zum anderen fehlen mit Bezug auf dieses Informationsangebot Daten zu den entsprechenden Netzinfrastrukturen. In den folgenden Kapiteln wird noch näher auf die Vor-, wie auch die Nachteile dieses bereits bestehenden Angebotes eingegangen. Ein weiterer Ansatz, den Energiebedarf für Wärme gebäude-spezifisch anzugeben, wird in Eicker et al. (2012), Nouvel et al. (2013), sowie (Nouvel et al. 2015) beschrieben. Hierbei wurde der Schwerpunkt auf die Erfassung von sehr hoch aufgelösten 3D – Gebäudemodellen gelegt, welche dazu dienen sollen, unter anderem Simulationen des Energiebedarfs durchführen zu können. Jedoch fehlt eine Einbindung in flächendeckende, ebenso wie in einheitliche Datensätze zur Ausweisung des Wärmebedarfs. Fallstudien zur Anwendung dieser 3D – Daten zur Wärmebedarfsberechnung und deren Auswertung beschreiben u.a. Eicker et al. (2012).

1.4. Wärmeplanung und Fernerkundung – eine Gegenüberstellung

Im Rahmen dieses Kapitels soll eine Gegenüberstellung dessen erfolgen, was kommunale Wärmeplanung einerseits fordert, und Fernerkundung andererseits leisten kann.

Basierend auf den vorherigen Kapiteln lässt sich aus planerischer Perspektive folgender Anforderungskatalog definieren:

- Verfügbarkeit **flächendeckender** Daten, welche Wärmebedarf basierend auf verschiedenen Indizes beschreiben
- Die vorliegenden Daten basieren auf einem **einheitlichen Konzept** zur Erfassung, sowie zur Analyse. Somit ist eine Vergleichbarkeit gewährleistet
- Aufgrund der Dynamik urbaner Strukturen sollten die vorliegenden Daten eine gewisse **zeitliche Flexibilität**, d.h. eine möglichst hohe zeitliche Auflösung, aufweisen. Somit wäre eine zeitlich präzise Berechnung des Wärmebedarfs möglich. Gleichzeitig bestünde die Möglichkeit, Entwicklungen über die Zeit zu beobachten und auf Basis berechneter Prognosen mögliche neue Planungsstrategien vorab zu bewerten
- Sinnvoll wäre eine **Integration bestehender Datensätze**, gerade mit Blick auf Baden – Württemberg. Ein resultierendes Modell zur Berechnung der jeweiligen Wärmebedarfswerte wäre auf dieser Datenbasis auch auf weitere Regionen anwendbar
- Ein Konzept zur Ermittlung von Wärmebedarfswerten sollte **flexibel variierbar** sein, um einerseits neue Datensätze mit einbinden zu können und andererseits, um auf variierende, bzw. neue Ansprüche der planerischen Akteure reagieren zu können

Diesen Anforderungen gegenüber steht das Potenzial der Fernerkundung:

- Verfügbarkeit flächendeckender, sowie konsistenter Daten
- Aufgrund der Vielfältigkeit vorhandener Sensoren die Bereitstellung von Informationen auf Basis verschiedenster spektraler Bereiche. Die Relevanz der jeweiligen Sensoren, bzw. deren Datenprodukte kann mittels statistischer Analyse ermittelt werden
- In Abhängigkeit des Sensors eine detaillierte zeitliche Abdeckung des zu untersuchenden Gebietes. Somit kann zeitlich flexibel auf Veränderungen, beispielsweise der räumlich strukturellen Merkmale einer Siedlung reagiert werden. Ebenfalls möglich sind Zeitreihenanalysen, um ggf. planerische Maßnahmen zu evaluieren

1.5. Zielsetzung der vorliegenden Arbeit

Die im vorhergehenden Kapitel beschriebene Gegenüberstellung macht deutlich, dass es verschiedene Deckungsbereiche zwischen einerseits der Anforderung an verfügbare Informationen zur Ableitung von Wärmebedarfswerten und andererseits der Möglichkeiten von (satellitengestützter) Fernerkundung im Allgemeinen gibt. Die vorliegende Arbeit richtet sich nach diesen Deckungsbereichen und definiert die Zielsetzung wie folgt:

Ziel dieser Arbeit ist es, ein Konzept zu entwickeln, welches verfügbare Daten satellitengestützter Sensoren mit bereits vorhandenen Datensätzen verknüpft. Diese Verknüpfung zielt darauf ab, hoch detaillierte Wärmebedarfswerte für den Raum Baden – Württemberg zu bestimmen. Um der Vielfältigkeit an den oben beschriebenen Möglichkeiten, dieses Ziel zu realisieren, Rechnung zu tragen, umfasst die Arbeit zwei Teilbereiche:

Zum einen wird, auf Basis eines satellitengestützten Sensors, eine Landbedeckungsklassifikation für Baden – Württemberg entwickelt. Diese Klassifikation soll als Grundlage dienen, um die weiteren Berechnungen in Abhängigkeit der jeweiligen Landbedeckung durchzuführen. Die hier angewandte Klassenunterteilung soll, im Sinne der kommunalen Wärmeplanung, relevante Klassen, wie beispielsweise Siedlungsbereich, industriell geprägt, oder auch Wälder unterteilen können.

Aufbauend auf der genannten Klassifikation soll ein Konzept entwickelt werden, welches durch die Verknüpfung mit vorhandenen Daten den Wärmebedarf von Wohngebäuden Baden – Württembergs bestimmen kann. Vorhandene Daten meint hierbei einerseits Ergebnisse bereits durchgeführter Studien, sowie andererseits abgeleitete Informationen auf Basis der im Rahmen dieser Arbeit genutzten Satellitendaten.

Eine detaillierte Beschreibung der hierfür genutzten Datensätze und Algorithmen wird in den folgenden Kapiteln gegeben.

Eine anschließende statistische Auswertung soll eine umfassende Analyse darüber ermöglichen, in wie weit die hier genutzten Informationen tatsächlich das bisherige Konzept der kommunalen Wärmeplanung im Allgemeinen, sowie in Baden – Württemberg im Speziellen, ergänzen können.

2. Genutzte Daten

Für die hier durchzuführende Klassifikation der Landbedeckung stellen Daten der Sentinel-2 – Satelliten die relevanten Informationen bereit. Dabei handelt es sich um flächendeckend verfügbare, sowie kostenlose Datensätze.

Die wesentlichen Vorteile dieses Sensors zum Zweck einer Klassifikation der Landbedeckung können wie folgt beschrieben werden (Drusch et al. 2012; Malenovsky et al. 2012; ESA 2015; Pesaresi et al. 2016; Radoux et al. 2016; TOPALOĞLU, Sertel, und MUSAOĞLU 2016; Zheng et al. 2017):

- **Freie Verfügbarkeit** der Daten
- **Wiederkehrzeit** von 5 Tagen. Dies bedeutet, dass die betrachteten Gebiete im 5-Tage – Intervall überflogen und aufgenommen werden. Diese hohe Wiederkehrrate wird aufgrund der Konfiguration erreicht, wobei Sentinel-2 aus einem Satellitenpaar besteht: Sentinel-2A und Sentinel-2B. Um 180°, im selben Orbit fliegend, versetzt, ermöglicht diese Konstellation eine hohe zeitliche Abdeckung
- Bedingt durch die benannte Wiederkehrzeit gibt es zahlreiche Szenen eines Gebietes mit lediglich **geringer Wolkenbedeckung**
- Eine **räumliche Auflösung** von zwischen 10m und 20m (Abbildung 3), je nach betrachteter Wellenlänge, ermöglicht eine räumlich hoch aufgelöste Klassifikation
- Das **Auflösungsvermögen im spektralen Bereich**, ebenso wie die spektralen Aufnahmebereiche (Abbildung 3) des Sensors ermöglichen mit Blick auf die Landbedeckungsklassifikation eine möglichst detaillierte Differenzierung der einzelnen Klassen. Für die hier durchgeführte Klassifikation wurden folgende Bänder genutzt:
 - B2, B3, B4, B81 (10m räumliche Auflösung)

- B7 (20m räumliche Auflösung)




Abbildung 3: Räumliche und spektrale Auflösung von Sentinel-2; Quelle: Müller et al. 2017: 9

Gerade der Red-Edge – Kanal (B7) ist zur Differenzierung von Vegetation überaus hilfreich, da in diesem spektralen Bereich der Übergang zwischen reflektierter Strahlung im sichtbaren einerseits, sowie im nahen Infrarot andererseits, wiedergegeben wird, wie u.a. Clevers und Gitelson (2012) beschreiben.

Die Datensätze werden auf dem Niveau des 1C – Levels bereitgestellt (ESA 2015). Hierbei wurden mit Blick auf die Rohdaten u.a. schon diverse radiometrische Korrekturen durchgeführt (siehe Abbildung 4).

Eine weitere Vorprozessierung (Level-2A), d.h. die Anwendung weiterer Algorithmen zur Korrektur der Daten kann manuell erfolgen (ESA 2012, 2015). Eine Beschreibung der im Rahmen dieser Arbeit angewandten Korrekturen wird im folgenden Kapitel gegeben.

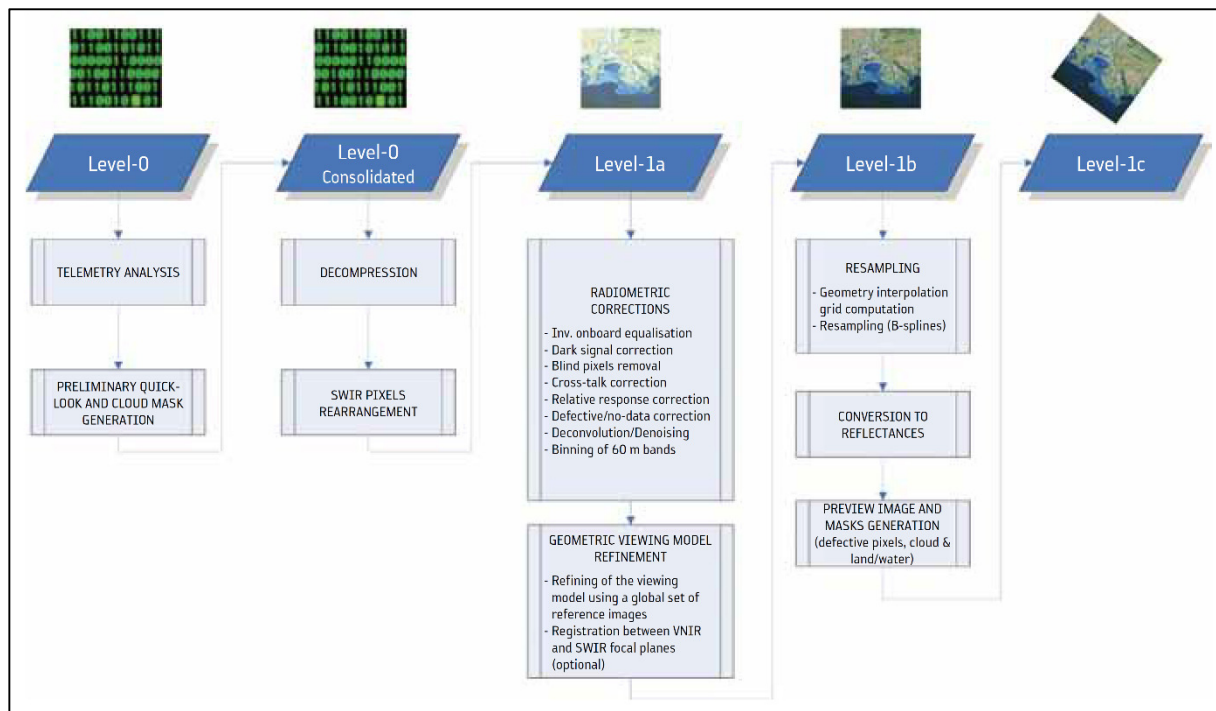


Abbildung 4: Prozessierung bis Level-1C; Quelle: ESA 2012: 43

Abbildung 5 zeigt die hier genutzten Szenen. Dabei stellen die Teilbilder a) und b) die beiden angesprochenen Szenen dar, welche zusammengeführt in Teilbild c) nahezu ganz Baden – Württemberg abdecken. Dargestellt werden die Szenen im RGB – Modus (Bänderkombination: R: B4; G: B3; B: B2).

Wie in Abbildung 5 ebenso ersichtlich, werden durch die beiden Szenen einige Bereiche im Osten des Landes nicht abgedeckt. Hierfür fehlten weitere Szenen dieses Bereiches in einem ähnlichen Zeitfenster bei gleichzeitig geringer Wolkenbedeckung. Weshalb dies dennoch im Rahmen dieser Arbeit zu keinen Problemen führt, wird im folgenden Kapitel erläutert.

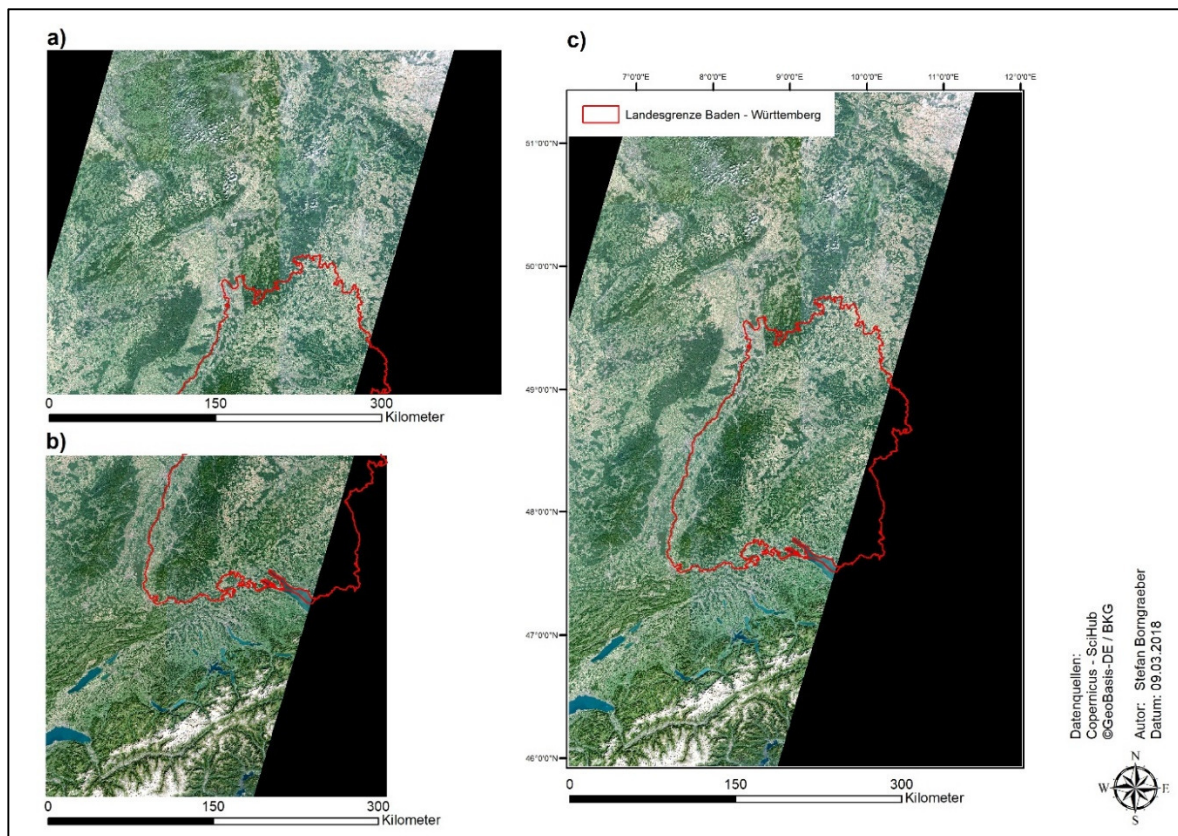


Abbildung 5: Übersicht der hier genutzten Sentinel-2 Szenen

Weitere Datensätze, welche im Zuge der Landbedeckungsklassifikation genutzt wurden, umfassen:

a) CORINE – LandCover

Dieser vektorbasierte Datensatz differenziert zwischen Polygonen gleicher Landnutzung und -bedeckung. Abgeleitet aus Satellitendaten, ebenso wie aus dem hier ebenfalls genutzten LBM-DE spiegeln die Polygone die wesentlichen Landnutzungsklassen für Deutschland wieder. Mit der Neuauflage, Stand 2012, konnte eine MKE (Mindestkartiereinheit) von einem 1ha erreicht werden. Dies bedeutet, dass Unterschiede in der Landnutzung, welche eine Fläche > 1ha umfassen, wiedergegeben werden können (Keil et al. 2011; Keil et al. 2015). Gleichzeitig besteht eine Lagegenauigkeit von $\pm 20\text{m}$. Hierbei gilt es zu beachten, dass diese Genauigkeit von den jeweils zugrundeliegenden Eingangsdaten abhängig ist. Entsprechend kann die Lagegenauigkeit Werte deutlich über 20m erreichen. Eine detaillierte Beschreibung der Generierung, sowie weiterer

Eigenschaften dieses Datensatzes kann u.a. Keil et al. (2015) entnommen werden.

Abbildung 6 zeigt eine Übersicht der verfügbaren Landbedeckungs-/Landnutzungsklassen in diesem Datensatz.

ARTIFICIAL SURFACES URBAN FABRIC 111 Continuous urban fabric 112 Discontinuous urban fabric INDUSTRIAL, COMMERCIAL AND TRANSPORT UNITS 121 Industrial, commercial and public units 122 Road and rail networks and associated land 123 Port areas 124 Airport MINES, DUMPS AND CONSTRUCTION SITES 131 Mineral extraction sites 132 Dump sites 133 Construction sites ARTIFICIAL NON-AGRICULTURAL VEGETATED AREAS 141 Green urban areas 142 Sport and leisure facilities AGRICULTURAL AREAS ARABLE LAND 211 Non-irrigated arable land PERMANENT CROPS 221 Vineyards 222 Fruit trees and berries plantations PASTURES 231 Pastures HETEROGENEOUS AGRICULTURAL AREAS 242 Complex cultivation patterns 243 Land principally occupied by agriculture, with significant areas of natural vegetation	FOREST AND SEMINATURAL AREA FORESTS 311 Broad-leaved forest 312 Coniferous forest 313 Mixed forest SCRUBS AND/OR HERBACEOUS VEGETATION 321 Natural grassland 322 Moors and heathland 324 Transitional woodland-scrub OPEN SPACES WITH LITTLE OR NO VEGETATION 331 Beaches, dunes, sand 332 Bare rock 333 Sparsely vegetated areas 334 Burnt areas 335 Glaciers and perpetual snow WETLANDS INLAND WETLANDS 411 Inland marshes 412 Peat bogs COASTAL WETLANDS 421 Salt marshes 423 Intertidal flats WATER BODIES INLAND WATERS 511 Water courses 512 Water bodies MARINE WATERS 521 Coastal lagoons 522 Estuaries 523 Sea and ocean
--	---

Abbildung 6: Klassen des CORINE2012 1ha – Produkts; Quelle: Keil et al. 2015: 22

b) Copernicus High Resolution Layers (HRL) – Forest HRL

Dieser rasterbasierte Datensatz gibt mit 20m – räumlicher Genauigkeit folgende Aspekte wieder (Langanke 2013):

- Bestandsdichte von Wäldern [%]. Hierbei wird je Pixel ein entsprechender Wert ausgegeben, welche den vorherrschenden Anteil an Wald pro Pixel wiedergibt
- Waldtyp – hierbei wird pro Pixel der vorherrschende Waldtyp angegeben. Dabei kann eine MKE von 0,5ha erreicht werden, bei gleichzeitigem Schwellwert von 10% Bewuchsdichte. Waldflächen, welche weniger als 5ha Fläche und weniger als 10% Bewuchsdichte aufweisen, können innerhalb eines Pixels entsprechend nicht erkannt werden. Prinzipiell erfolgt die Typunterscheidung zwischen Laub- und Nadelwald.

Die folgenden beiden Datensätze dienen lediglich als Input für den zweiten Teil dieser Arbeit – der Klassifikation des Wärmebedarfs.

a) LBM-DE 2015

Tabelle 1: Klassenschema des LBM-DE 2015

A	Bebauung	B110
	Anlagen	B121
	Versiegelte gebäudelose Flächen	B122
	Mischflächen (regelmäßige Struktur)	B242
B	Ackerland	B211
	Weinbau	B221
	Obst- und Beerenobst	B222
	Hopfen	B224
C	homogenes Grünland	B231
	inhomogenes Grünland	B321
	Grasland mit Bäumen (< 50%)	B233
D	Zwergsträucher (Heide)	B322
	Büsche, Sträucher	B324
	Aufforstung	B310
	Laubbäume	B311
	Nadelbäume	B312
	Nadel- und Laubbäume	B313
E	Sand, Steine, Erde	B330
	Fels	B332
	Brandfläche	B334
	Schnee (permanent) und Eis	B335
F	Sumpf	B411
	Moor	B412
	Sumpf mit Büschen/Bäumen < 50%	B413
	Moor mit Büschen/Bäumen < 50%	B414
G	Watt	B423
	Wasserlauf	B511
	Wasserfläche	B512
	Lagune	B521
	Mündungstrichter	B522
	Offenes Meer	B523

Dieser vektorbasierte Datensatz gibt ebenfalls Landbedeckung und Landnutzung wieder. Jedoch liegen hier andere Datensätze zugrunde.

So wurden u.a. bereits vorhandene Informationen des ATKIS® Basis – DLM, sowie Satellitendaten miteinbezogen (BKG 2018). Tabelle 1 stellt die hier differenzierten Klassen dar. Die jeweiligen Polygone weisen eine MKF von 1ha auf. Aufgrund der Mindestkartierbreite (MKB) von 15m wurden sehr schmale Objekte nicht erfasst.

Quelle: BKG 2015: 9

b) 3D – Gebäudemodelle (LoD1)

Diese modellierten Gebäude liegen ebenfalls als Vektordatensatz vor. Wie Abbildung 7 zeigt, existieren verschiedene LoD – Stufen (Level of Detail). Sämtliche Stufen beinhalten die Grundrisse der jeweiligen Gebäude. Je nach Stufe werden zusätzlich gebäudescharfe Informationen, wie beispielsweise die Dachform, hinzugefügt.

Speziell für Baden – Württemberg gilt zu bemerken, dass die Stufe LoD1 aus LoD2 abgeleitet worden ist (Gültlinger 2015; LDBV 2017).

Zusätzlich zu den Gebäudeumrissen sind die jeweiligen Höheninformationen vorhanden (Abbildung 7). Dabei maßgeblich ist die Generierung dieser Information – im Falle von dem hier genutzten LoD1 wird für sämtliche Gebäude die Form eines Flachdaches angenommen. Dementsprechend ist auch der Begriff „Klötzchenmodell“ zu verstehen. Die Lagegenauigkeit der Gebäude

steht in direkter Abhängigkeit der zugrundeliegenden Grundrisse des digitalen Liegenschaftskatasters, oder auch aus ATKIS® entnommen (LDBV 2017). Damit kann eine Lagegenauigkeit von ca. 0,5m angenommen werden. Die Höhengenaugkeit kann je nach Komplexität der Dachform schwanken, ist aber bei $\pm 5\text{m}$ einzuordnen.

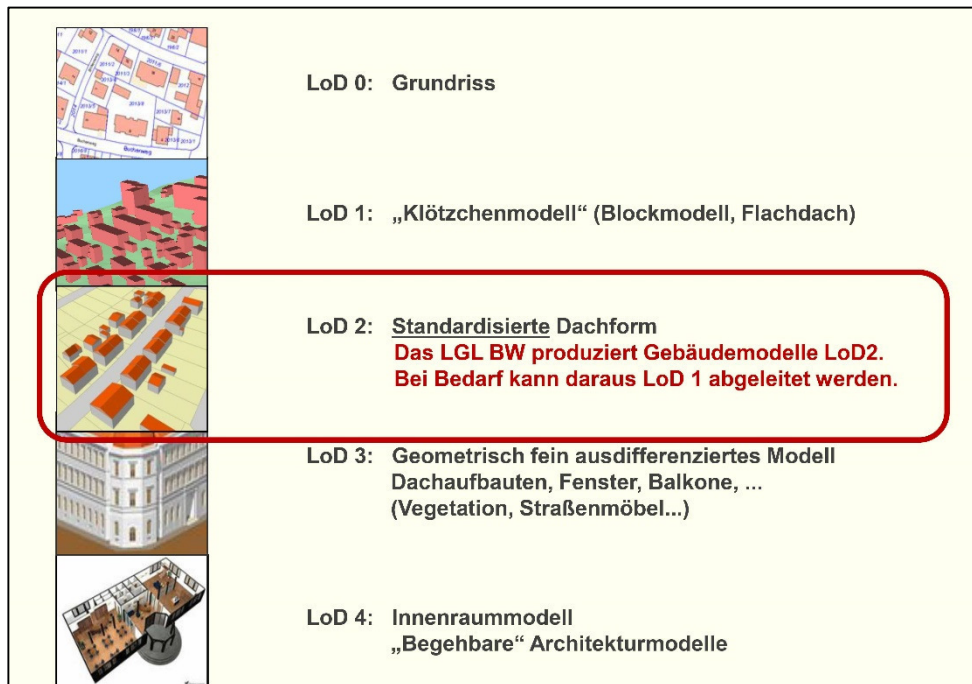


Abbildung 7: Übersicht der verschiedenen Detail – Stufen; Quelle: Gültlinger 2015: 8

c) Gebäudetypologie

Diese Datenbasis ist für den zweiten Teil dieser Arbeit, die Klassifikation des Wärmebedarfs von Wohngebäuden, von größter Relevanz. Hierbei wurden für gesamt Deutschland Gebäudetypen entsprechend des jeweiligen Baualters, sowie des Gebäudetyps definiert.

Abbildung 8 stellt ein Beispiel eines Gebäudetyps aus diesem Datensatz dar. Gezeigt ist der Gebäudetyp eines Einfamilienhauses (EFH) der Baualtersklasse 5 (1958...1968).

EFH_E		Heizsystem-Variante 1	1958 ... 1968	DE.N.SFH.05.Gen
Beispielgebäude		Gebäudetyp Klassifizierung (TABULA Code)		
		► Land	DE	Deutschland <i>Germany</i>
		► Typologie Region	N	nicht regional spezifiziert <i>National</i>
		► Größenklasse	SFH	Einfamilienhaus ("EFH") <i>Single Family House</i>
		► Baualtersklasse	5	[E] 1958 ... 1968
		► Zusatz-Kategorie	Gen	Grund-Typ <i>Generic</i>
beheizte Wohnfläche	110 m²	Charakterisierung des Gebäudetyps		
Anzahl Vollgeschosse	1	typisch 1- oder 2-geschossig, mit Satteldach, Dachgeschoss beheizt; bis-weißen auch 1-geschossig mit Flachdach; Betondecken; Mauerwerk aus Hohlblocksteinen, Gitterziegel, Holzspansteinen o.ä., verputzt; in Norddeutschland meist zweischalig unverputzt		
Anzahl Wohnungen	1			

Abbildung 8: Beispieltyp für Einfamilienhaus; Quelle: Loga et al. 2015: 32

Wie in dieser Abbildung angedeutet, richtet sich die Einordnung des Typs u.a. nach der Anzahl der Wohnungen, sowie der Anzahl an Vollgeschossen. Weiterhin wird für jeden Typ die beheizte Wohnfläche angegeben (Loga et al. 2015). Generell baut sich dieser Datensatz u.a. aus der Zuhilfenahme der Zensus – Erhebung des Landes auf (Diefenbach 2013). Zusätzlich wurden Fragebögen entwickelt, welche für den Wärmebedarf relevante Gebäudeparameter abfragen. Unterschieden wird hierbei generell zwischen

- a) Konstruktionen, wie beispielsweise Dach, Außenwand und Fenster, sowie
- b) Wärmeversorgung, d.h. Heizsystem und Warmwassersystem.

Somit stellen Musterhäuser, wie in Abbildung 9 gezeigt, den typischen Wohngebäudebestand Deutschlands dar. Hinsichtlich des Wärmebedarfs eines Typs wurden verschiedene Sanierungsmaßnahmen in Form von Szenarien definiert (siehe Beispiel in Abbildung 9). Diese Szenarien bilden ab, in wie weit Veränderungen der Konstruktionen, bzw. der Wärmeversorgung den Wärmebedarf des jeweiligen Gebäudetyps beeinflussen.




Abbildung 9: Beispiel für Sanierungspakete; Quelle: Loga et al. 2015: 36

Zusätzlich zu weiteren Parametern wird, wie Abbildung 9 zeigt, für jeden Gebäudetyp, bzw. für jedes zugehörige Modernisierungspaket der Netto – Heizwärmebedarf angegeben. Dieser wurde im Zuge der vorliegenden Arbeit als Basis genutzt.

Die Beschreibung der weiteren Gebäudetypen, sowie weiterer Details zu diesem Datensatz sind Loga et al. (2015) zu entnehmen.

3. Klassifikation der Landbedeckung

Dieses Kapitel stellt die Arbeitsschritte im Kontext der Vorprozessierung der genutzten Daten vor. Aufbauend darauf werden die Ergebnisse der Landbedeckungsklassifikation betrachtet.

3.1. Methodik

3.1.1. Vorprozessierung der Sentinel-2 – Daten

Wie bereits oben angedeutet, besteht die hier genutzte Szene für Baden – Württemberg aus zwei Aufnahmen, welche jeweils in der Level-1C – Prozessierung bezogen wurden. Entsprechend wurde hier initial für jede der beiden Szenen der Algorithmus (Sen2Cor) nach Müller-Wilm, Devignot, und Pessiot (2017) angewandt, damit die finale Szene im Level-2A vorliegt.

Abbildung 10 zeigt die im Rahmen dieses Algorithmus angewandten Prozessierungen. Besonders relevant ist hier die atmosphärische Korrektur der Szenen, welche die folgenden Schritte umfasst:

- Berechnung der AOT (Aerosol Optical Thickness). Hierbei wird die rein visuelle Durchlässigkeit der Atmosphäre berechnet, und in einem definierten Parameter abgelegt
- Berechnung des Anteils an Wasserdampf in der Luft (WV)
- Korrektur von Wolkenbedeckung
- Berechnung der Oberflächenrückstreuung

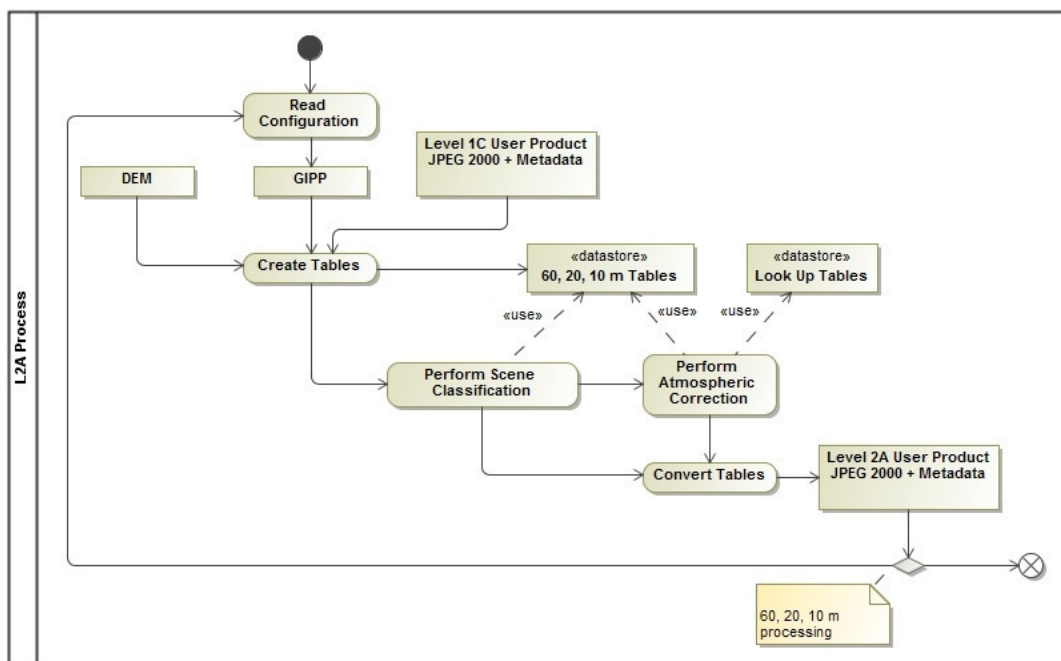


Abbildung 10: Workflow der Level-2A – Korrektur; Quelle: Müller et al. 2017: 12

Somit kann eine weitgehende Korrektur des Einflusses der Atmosphäre auf die Reflexion durchgeführt werden. Das Level-2A Produkt gibt demnach die BOA - Reflexion (bottom of atmosphere) wieder, gegenüber der TOA – Reflexion (top of atmosphere) des Level-1C Produktes.

Abbildung 11 gibt den Effekt der genannten korrektiven Rechenschritte wieder. Dabei stellt das linke Teilbild den Zustand des Level-1C Produktes dar, während im rechten Teilbild die Berechnungen angewandt worden sind.



Abbildung 11: Effekt der Atmosphärenkorrektur; Quelle: Müller et al. 2017: 19

An dieser Stelle macht sich die spektrale Bandbreite der Sentinel-2 Sensoren bemerkbar, da sämtliche spektrale Informationen, welche für die beschriebenen Korrekturen notwendig sind, bereits in der Bandbreite enthalten sind.

Nach dieser Korrektur der beiden Einzelszenen wurde eine Gesamtszene, wie in Abbildung 6 bereits gezeigt, erstellt. Beim Zusammenfügen wurde darauf geachtet, einen ausreichenden Überschneidungsbereich zu erhalten, um Kantenbildung in Bereichen der Randpixel vorzubeugen.

3.1.2. Ableitung von Texturen

Auf Grundlage der hier genutzten 5 Bänder wurden Grauwert – Matrizen (GLCMs) berechnet. Grund für diesen Arbeitsschritt ist, in Anlehnung an Haralick, Shanmugam, und Dinstein (1973), Haralick (1979), sowie Irons und Petersen (1981) die Idee, nicht nur reine Reflexionswerte auf Basis des jeweiligen elektromagnetischen Spektrums in die Klassifikation mit einfließen zu lassen. Vielmehr sollen auch die Bezüge zwischen den einzelnen Pixeln, bzw. zwischen deren Grauwerten ausgewertet werden. Somit können Textur – bezogene Änderungen im Bild, beispielsweise der räumliche Übergang zwischen Acker und Siedlung, oder auch zwischen Wald und Wiese besser erkannt und demnach klassifiziert werden.

Maßgeblich mit Bezug auf die Berechnung von GLC – Matrizen ist die jeweilige Parametrisierung von Grauwertbereich, Kernelgröße und Richtung. Im Rahmen der hier

durchgeführten Klassifikationen der Landbedeckung wurden diese Parameter wie folgt definiert:

- Der **Grauwertbereich** als geschlossenes Intervall umfasst Werte von $[0,31]$. Aufgrund der Tatsache, dass die Sentinel-2 – Daten in höheren Bit – Tiefen (16-Bit) vorliegen, wurde im Vorfeld der GLCM – Berechnung ein linearer Stretch auf 5-bit gerechnet. Gleichsam wurden die Daten von Ausreißern nach oben und unten bereinigt. Für diesen Histogrammausgleich wurde die Obergrenze der Quintile auf 0,99 und die Untergrenze auf 0,01 gesetzt.
- Die **Kernelgröße** beträgt 3×3 . Demnach werden je Richtung 3 Nachbarn in die Berechnung der Texturvariablen miteinbezogen. Mit Blick auf die räumliche Auflösung von 10m würde ein größerer Kernel potenziell über Klassen hinweg Texturen berechnen, welche entsprechend nicht zur Differenzierung herangezogen werden könnten.
- Die Nachbarschaften wurden für alle **Richtungen** ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) analysiert, da im Vorfeld keine klare Richtungsabhängigkeit der Texturverläufe ersichtlich war.

Folgende **Texturmaße** wurden berechnet: Mittelwert, Varianz, Homogenität, Kontrast, Disssimilarität, Entropie und second-moment. Die jeweiligen Formeln und Hintergründe zur Berechnung können beispielsweise in Haralick (1979) nachgeschlagen werden.

3.1.3. Klassifikator

Für sämtliche hier angewandte Klassifikationen wurde Random Forest als Klassifikator genutzt. Abbildung 12 zeigt schematisch die Funktionsweise dieses Algorithmus. In Anlehnung an Breiman (1992, 1996, 2001), Gislason, Benediktsson, und Sveinsson (2006), Belgiu und Drăguț (2016), sowie Kulkarni und Lowe (2016) kann die Funktionsweise wie folgt beschrieben werden:

Generell kann Random Forest als sog. „ensemble classifier“ aus dem Bereich der maschinellen Lernverfahren bezeichnet werden. Dies bezieht sich auf die Tatsache, dass mehrere Berechnungen, bzw. mehrere Schritte vollzogen werden, welche zu einer finalen Klassifikation des vorliegenden Datensatzes führen. Im Falle von Random

Forest umfassen diese Schritte im Wesentlichen den nach Breiman (1996) beschriebenen Ansatz des „Bagging“ in Kombination mit der multiplen Erstellung von decision-trees. Der Begriff „Bagging“ leitet sich hier aus zweierlei Prinzipien ab: „bootstrap“, sowie „aggregating“. „Bootstrap“ beschreibt das zufällige Ziehen von Variablen, welche zur Erstellung der decision-trees genutzt werden. Wichtig hierbei ist, dass die gezogenen Variablen weiterhin zur Grundgesamtheit gehören – das Ziehen erfolgt also mit Zurücklegen der Variablen. Dieses statistische Verfahren wird im Zuge der Erstellung der decision-trees angewandt, auf Basis eines initial gegebenen Trainings – Datensatzes (Training-Phase in Abbildung 12). Dieser enthält neben den unabhängigen Variablen, beispielsweise satellitenbasierten Reflektionswerten, die jeweilige Klassenzuweisung (abhängige Variable).

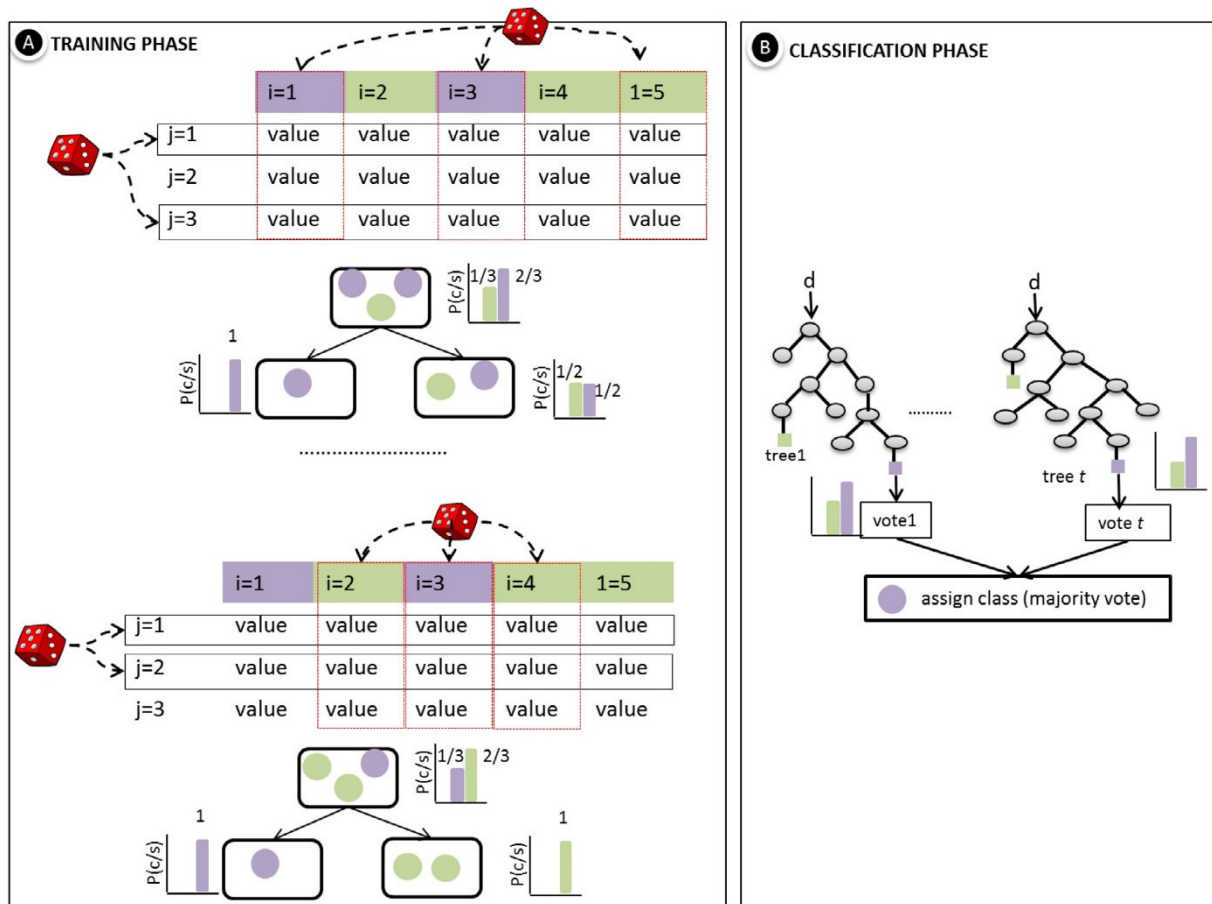


Abbildung 12: Schematische Beschreibung von Random Forest [i = abhängige Variablen; j = unabhängige Variablen; p = Wahrscheinlichkeit, c = Klasse; s = Grundgesamtheit; t = Anzahl der Bäume; d = zu klassifizierender Datensatz];

Quelle: Belgiu & Dragut 2016: 26

Wird pro Baum die Wahl des Samples variiert, so erfolgt pro Knoten eine jeweils neue zufällige Ziehung einer definierten Anzahl ($mtry$) unabhängiger Variablen (siehe Abbildung 12). Auf diese Weise basiert jeder Baum auf verschiedenen Kombinationen an

Variablen und dementsprechend auf verschiedenen Regeln, welche zu einer Klassenzuweisung führen. Wurde auf Basis dieser zufälligen Komponenten eine definierte Anzahl (*ntree*) an Bäumen erstellt, kann der entsprechende Wald (Random Forest) als Modell zur Klassifikation der Gesamtszene genutzt werden. Diese fußt auf dem zweitgenannten Prinzip der Aggregation. Dabei durchläuft jede zu klassifizierende räumliche Einheit (beispielsweise ein Gebäude) sämtliche Bäume, wobei jedem Baum diejenige Klassifikation mit der höchsten prognostizierten Wahrscheinlichkeit zugewiesen wird. Jene Klasse, welche am häufigsten klassifiziert wurde, wird als finale Klassifikation gesetzt (majority vote).

Mit Verweis auf die obige schematische Beschreibung des Klassifikators leitet sich die Wahl dessen aus folgenden Merkmalen ab, welche im Kontext der vorliegenden Arbeit als Vorteile angesprochen werden können:

- Die initiale Parametrisierung des Algorithmus bedarf nur weniger Definitionen. Lediglich die Anzahl der zu modellierenden Bäume (*ntree*), sowie die Anzahl der zu wählenden unabhängigen Variablen pro Knoten (*mtry*) müssen gesetzt werden. Aufgrund dessen sind diverse statistische Analysen im Vorfeld der Klassifikation hinfällig
- Die implementierte Zufallskomponente dieses Ansatzes ermöglicht es, eine möglichst hohe Varianz zwischen den Klassen einerseits und eine möglichst geringe Bias andererseits zu erreichen. Bias meint hierbei eine mit statistischen Mitteln nicht zu erfassende wertbezogene Streuung zwischen den Klassen. Gleichzeitig können alle verfügbaren unabhängigen Variablen zur Klassifikation herangezogen werden, wobei deren Auswahl pro Knoten auf statischen Maßzahlen, wie der Minimierung der Entropie, beruht
- Die Anforderung gegenüber dem Umfang an Trainingsdaten ist gering. Dies leitet sich daraus ab, dass auf Grundlage der Zufallskomponenten des Algorithmus Klassifikationsmodelle erstellt werden können, welche die Variation innerhalb und zwischen den Samples wiedergeben. Entsprechend kann eine explizite Trennung der Zielklassen erreicht werden. Dennoch ist es erforderlich, dass die verfügbaren Trainingsdaten die volle Variabilität der zugrundeliegenden

Klassen hinsichtlich der genutzten Informationen, wie beispielsweise Satelliten-
daten abdecken.

- Das Skalenniveau der verschiedenen unabhängigen Variablen muss nicht angepasst werden, da im Zuge des Trainingsprozesses keine absoluten Bezüge zwischen den Variablen hergestellt werden. Vielmehr werden relative Bezüge zwischen (abgeleiteten) statischen Maßzahlen zur Entwicklung der einzelnen Bäume genutzt.
- Die maximale Laufzeit des Algorithmus ist gegenüber anderer maschineller Lernverfahren, wie beispielsweise Support Vector Machines, wesentlich kürzer. Diese Tatsache leitet sich u.a. daraus ab, dass der Klassifikationsprozess (classification phase in Abbildung 12) pro Durchlauf eines Baumes getrennt verläuft und somit parallel verarbeitet werden kann. Dies ist gerade für umfangreiche Datensätze, wie der hier verarbeitete eines Bundeslandes, von Vorteil

Die **Parametrisierung** von Random Forest im Kontext der vorliegenden Arbeit ist wie folgt:

- Die Anzahl der zu berechnenden Bäume (*ntree*) wurde auf 500 gesetzt
- Die Anzahl der zu nutzenden unabhängigen Variablen pro Knoten berechnet sich aus \sqrt{n} (wobei $n = \text{Anzahl der unabhängigen Variablen}$)

Die Anwendung der bisher beschriebenen Methodiken erfolgt mit Blick auf die Klassifikation der Landbedeckung in zwei Phasen. Hintergrund hierfür ist, dass im Rahmen der ersten Phase im räumlichen Kontext eines kleinen Testgebietes verschiedene Variationen hinsichtlich

- a) der Frage, welche Daten für das Trainieren der Gesamtszene genutzt werden und
- b) welche Daten zur Validierung der Gesamtszene herangezogen werden können, sowie
- c) der Entscheidung, welches Klassenschema zur Differenzierung der entsprechenden Daten im vorliegenden Kontext am besten geeignet ist,

durchgeführt werden sollen.

Gerade mit Blick auf die für Training und Validierung genutzten Daten soll analysiert werden, welche Genauigkeiten eine Kombination von visueller Bildinterpretation und bereits bestehenden Datensätzen liefert. Da visuelle Bildinterpretation mit einem erheblichen Zeit- und Arbeitsaufwand verbunden ist, wäre es hier attraktiv, diese zum Training verwenden zu können, da, wie oben beschrieben, nur ein geringer Umfang an Trainingsdaten benötigt wird. Gleichzeitig könnten bestehende und flächendeckende Datensätze zur Validierung herangezogen werden, da hier die Ansprüche an den Umfang deutlich höher sind, um eine aussagekräftige Validierung erstellen zu können.

Zum Beantworten dieser Fragen gründet sich die hier angewandte Methodik auf der Variation folgender Parameter:

- Einbezug von GLCM – Berechnung. Hier soll der Einfluss der GLC – Matrizen auf die Klassifikationsgenauigkeit abgeschätzt werden
- Das Klassenschema. Hier soll abgeschätzt werden, in wie weit spektral ähnliche Klassen die Klassifikationsgenauigkeit beeinflussen
- Datensatz zum Trainieren und Validieren. Dazu wurden zwei Datensätze zusammengestellt:
 - Samples aus einer visuellen Bildinterpretation (s.u.)
 - Samples auf Basis der CORINE / Copernicus HRL – Daten (Ausnahme bilden hier die Klassen 11 und 12 s.u.)

Im Falle der interpretierten Samples erfolgt die Klassenzuweisung direkt auf Basis des jeweils angewandten Klassifikationsschemas. Hingegen fußt die Klassenzuweisung des zweiten Datensatzes, speziell der CORINE – Daten, auf der entsprechenden Nomenklatur (siehe Tabelle 2). Analysiert werden soll nun, in wie weit sich die Genauigkeit verändert, wenn verschiedene Datensätze zum Trainieren, bzw. Validieren herangezogen werden.

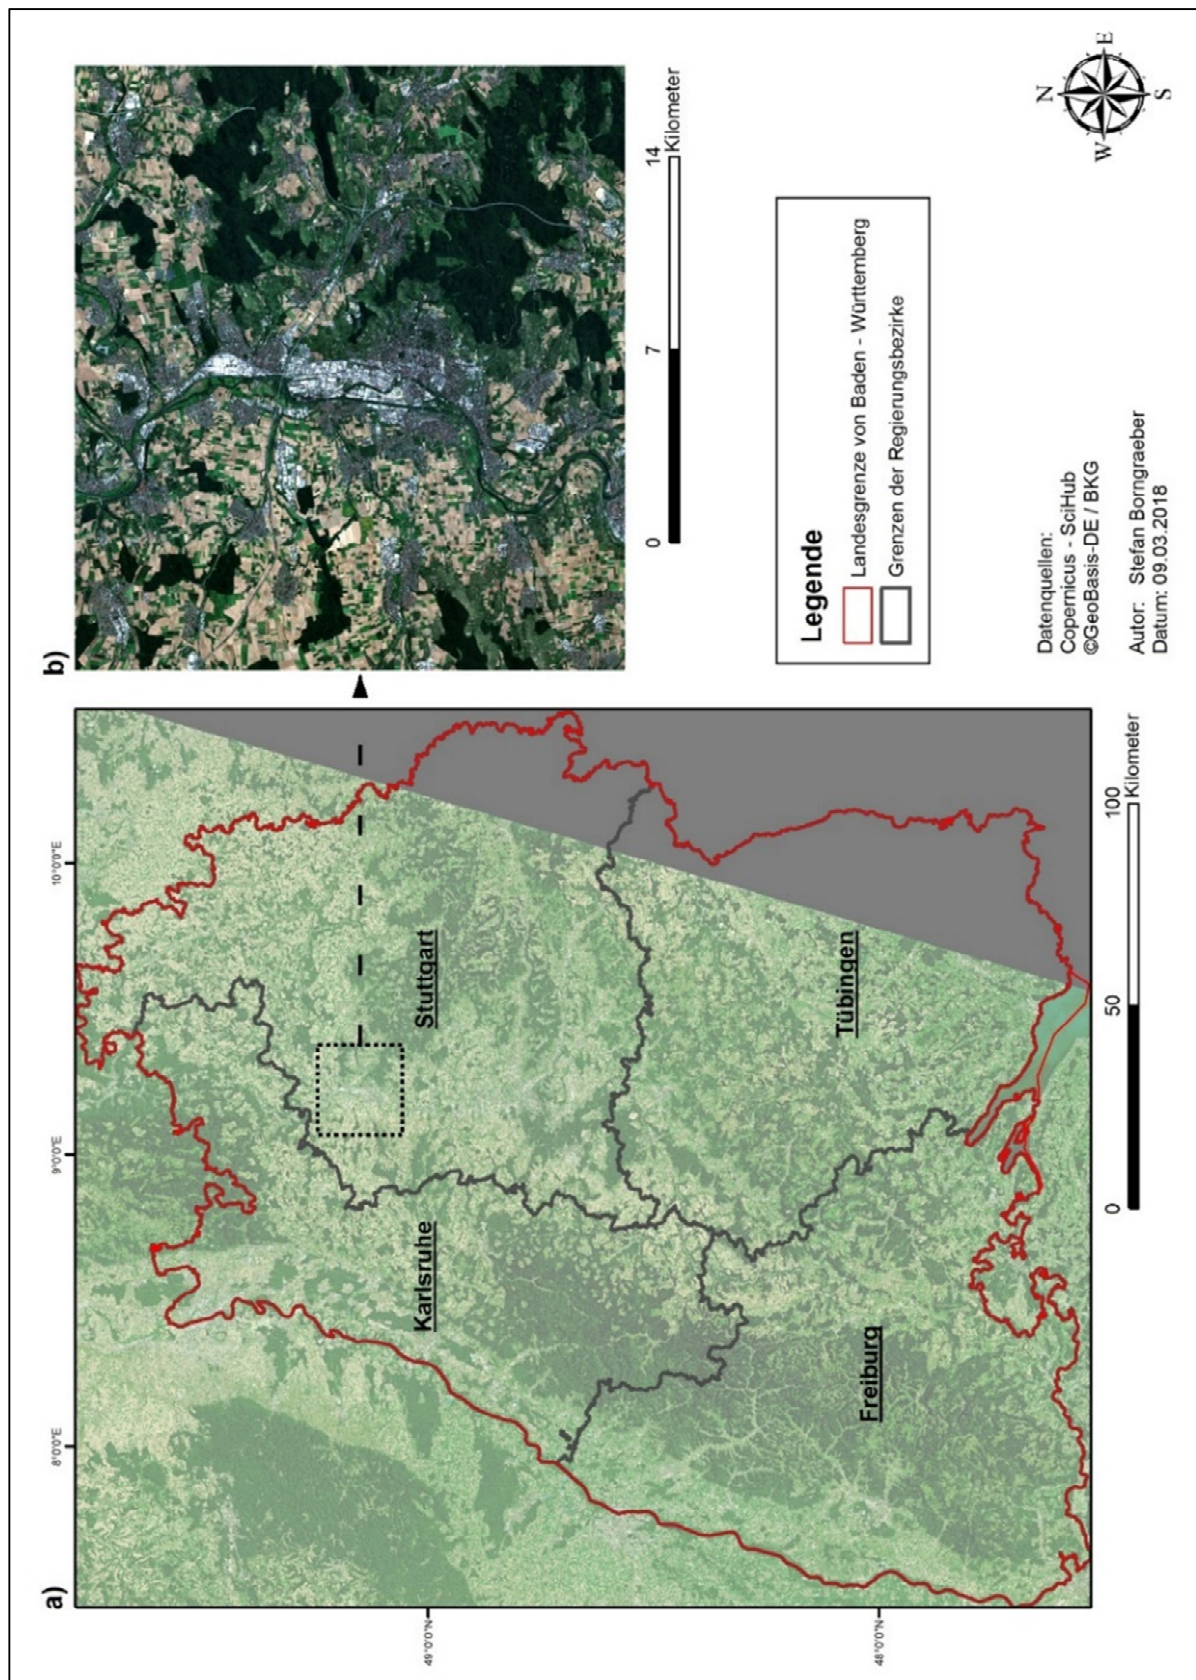


Abbildung 13: Testgebiet Heilbronn [a) Gesamtszene Baden – Württemberg; b) Heilbronner Testgebiet]

Da die vorliegenden Datensätze (Kapitel II) verschiedenen Datenquellen entstammen, erfolgt die quantitative Einordnung der Klassifikation des Testgebietes auf Basis der

statistischen Auswertung des Accuracy Assessments. Jene Variation mit den höchsten Genauigkeiten wird für die Gesamtszene genutzt.

3.1.4. Phase 1 – Klassifikation des Testgebietes

Zum Testen der oben beschriebenen Variationen an Daten wurde das Gebiet um Heilbronn gewählt (siehe Abbildung 13). Grund hierfür ist die Tatsache, dass im entsprechenden Ausschnitt sämtliche relevanten Klassen vertreten sind, und, dass gleichsam das Stadtgebiet eine komplexe Struktur aufweist – dies bezieht sich einerseits auf die Vermischung von Siedlungsbereichen, sowie innerstädtischem Grünland und andererseits auf die teils kleinräumige Mischung von Siedlungs- und Industrieflächen. Ebenfalls von Vorteil ist, dass mit dem Flusslauf des Neckars durch die Stadt ausreichend Wasserflächen zur Klassifikation gegeben sind.

3.1.4.1. Klassenschema und Sampling

Tabelle 3 zeigt das initiale Klassenschema zur Differenzierung der vorherrschenden Landbedeckung. Gleichzeitig sind die jeweiligen CLC – Codes (entsprechend der Nomenklatur nach Keil et al. (2011)) aufgeführt, welche hier genutzt wurden, um die relevanten CORINE – Daten zu selektieren. Anzumerken ist hierbei, dass die Klassen 11 und 12 aus dem Forest-HRL – Datensatz (siehe Beschreibung Kapitel II) stammen. Ebenfalls war es nicht möglich, die Ackerflächen auf Basis der CORINE – Daten nach bewirtschaftet, bzw. brach liegend zu differenzieren. Entsprechend wurden diese Flächen mittels visueller Bildinterpretation der vorliegenden Sentinel – Szene erfasst.

Bereits im Vorfeld wurde festgelegt, dass weder Straßen, noch innerstädtische Grünflächen explizit klassifiziert werden sollen. Ausschlaggebend hierfür ist die grundlegende Annahme, dass sich diese beiden Klassen weder spektral, noch auf Basis der Texturen bei einer räumlichen Auflösung von 10m von den jeweils anderen Klassen trennen lassen. Die letzten beiden Spalten in Tabelle 2 zeigen die Klassenschemata, die in Abhängigkeit der betrachteten Variation (s.u.) definiert wurden.

Tabelle 2: Initiales Klassenschema

ID	Klasse	CLC_CODE	Varianten 1 und 2	Varianten 3 bis 9
11	Laubwald	-	[x]	[x]
12	Nadelwald	-	[x]	
13	Wiese	231; 222; 221	[x]	
21	Acker bewirtschaftet	-	[x]	[x]
22	Acker brachliegend	-	[x]	[x]
31	Wohngebiet	111; 112	[x]	[x]
32	Industrie	121; 123	[x]	[x]
40	Wasser	511; 512	[x]	[x]

Für Training und Validierung der Klassifikationsdurchläufe wurden neben den in Tabelle 2 angedeuteten Daten vorhandener Datensätze zusätzlich Flächen auf Basis visueller Bildinterpretation der Sentinel-2 – Szene erhoben. Durch diese können, wenn als absolute Referenz definiert, im Zuge einer Validierung potenzielle Fehlerquellen und Ungenauigkeiten bezüglich Lage und Klassenzuweisung ausgeschlossen werden.

Tabelle 3: Referenzdaten und Sampling

Variationen	Datensätze	Laubwald	Nadelwald	Wiese	Acker bewirt.	Acker brach	Wohngebiet	Industrie	Wasser	Gesamt
Variationen 1 und 2	Training	17	7	24	109	163	73	25	10	428
	Validierung	15	24	33	156	107	57	36	4	432
Variationen 3 bis 9	Training	24			133	163	73	25	10	428
	Validierung	39		-	189	107	57	36	4	432

Tabelle 3 zeigt die hierbei angewandte Verteilung dieser Samples für Training, bzw. Validierung pro Klasse.

Die Farbgebung von Tabelle 3 deutet an, welche Klassen im Zuge der Variationen aggregiert wurden: während im Rahmen der ersten beiden sämtliche Klassen genutzt wurden, so wurde für die Variationen 3 bis 9 folgende Zusammenführung vorgenommen:

- Klasse 12 wurde Klasse 11 zugerechnet und

- Klasse 13 wurde Klasse 21 zugerechnet.

3.1.4.2. Variationen der Klassifikation

Im Sinne der Übersichtlichkeit werden vorab folgende Abkürzungen definiert:

- „Ref“ bezeichnet jene Samples, die auf Basis visueller Bildinterpretation erstellt worden sind
- „COR / Cop“ steht für die Samples, welche dem CORINE-, bzw. Copernicus-HRL – Datensatz entnommen worden sind

Tabelle 4: Varianten 1 bis 4

Varianten	Merkmale (<u>S</u> pektral, <u>T</u> extur)	Anzahl Klassen	Training	Validierung
1	S	8	Ref	Ref
2	S + T	8	Ref	Ref
3	S	6	Ref	Ref
4	S + T	6	Ref	Ref

Tabelle 4 stellt die der ersten 4 Varianten gegenüber. In diesen ersten Klassifikationsdurchläufen soll der Einfluss der GLCM – Information, sowie des jeweiligen Klassenschemas analysiert werden. Sämtliche weiteren Parameter bleiben konstant, um einen eindeutigen Rückschluss der Klassifikationsgenauigkeit auf den sich variierenden Parameter zu ermöglichen.

Demgegenüber stehen die Klassifikationsansätze in Tabelle 5. Konstant sind hier neben den Sentinel – Bändern die GLCM – Werte, sowie das Klassenschema. Vielmehr liegt der Fokus auf der Variation der dem Training, bzw. der Validierung zugrundeliegenden Daten, sowie auf dem Nutzen der beiden Datensätze und der Frage, ob die genutzten Datensätze kombiniert werden können. Weiterhin soll die Eignung des alleinigen Nutzens der CORINE-, bzw. Copernicus-HRL – Daten zum Training, wie auch zur Validierung analysiert werden.

Für die Varianten 8 und 9 wurde ein dritter Datensatz aus den COR / Cop – Daten abgeleitet (**COR / Cop***). Dabei wurden auf Basis einer räumlichen Abfrage diejenigen Flächen der COR / Cop – Datensatzes selektiert, welche Überschneidungsbereiche mit den Ref – Daten aufweisen. Der entsprechende Grundgedanke hierbei zielt darauf

ab, die Lagegenauigkeit der Referenzdaten mit dem thematischen Inhalt der COR- / Cop – Daten zu verbinden. In wie weit sich diese Verbindung mit Blick auf die Genauigkeit niederschlägt, wird im folgenden Kapitel näher betrachtet.

Tabelle 5: Varianten 5 bis 9

Varianten	Merkmale (Spektral, Textur)	Anzahl Klassen	Training	Validierung
5	S + T	6	COR / Cop	Ref
6	S + T	6	Ref	COR / Cop
7	S + T	6	COR / Cop	COR / Cop
8	S + T	6	COR / Cop	COR / Cop*
9	S + T	6	COR / Cop*	Ref

Im Gegensatz zu sämtlichen weiteren Klassifikationen wurde jene des Testgebietes mit der RStoolbox der R – Umgebung durchgeführt. Während die Parametrisierung wie oben beschrieben vorgenommen wurde, so unterscheidet sich die Anwendung der Validierung. Basieren die Klassifikationen für die Gesamtszene jeweils auf einer separat durchgeführten Validierung, so wurde hier die funktionsinterne Variante gewählt. Aus Platzgründen entfällt eine entsprechende detaillierte Beschreibung an dieser Stelle. Für weitergehende Informationen kann das zugrundeliegende Skript bei Leutner und Horning (2018) eingesehen werden. Wichtig jedoch ist, dass im Zuge der Validierung ein separater Datensatz (wie in Tabelle 3 gezeigt) genutzt wurde. Somit war eine ausreichende Grundgesamtheit für den Prozess des Trainings einerseits und jenen der Validierung andererseits gegeben.

Da die Daten zum Training sowie zur anschließenden Validierung als Polygone vorliegen, müssen mittels eines Sampling – Verfahrens punktuell Stichproben für die Validierung gezogen werden. Im Kontext des hier genutzten Verfahrens steht die Anzahl dieser Stichproben pro Klasse in Relation zur Fläche der jeweiligen Polygone, sowie zur Anzahl von Polygonen je Klasse. So sind beispielsweise für große Waldflächen mehr Stichproben zu erwarten, als für kleinräumige Acker-, oder Wiesenflächen. In der Konsequenz bedeutet dies, dass keine feste Anzahl an Samples definiert wurde, sondern, dass diese Anzahl flexibel auf Umfang und relative Flächengröße der Samples reagiert.

3.1.5. Phase 1 – Ergebnisse

Im Folgenden werden die Klassifikationsgenauigkeiten der ersten Phase analysiert. Dabei zum Ansatz kommen im Wesentlichen drei Indizes, welche die Genauigkeit repräsentativ wiedergeben. Es wurde mit Verweis auf Congalton (1991), Stehman (1995) und Stehman (1997) eine Auswahl an Indizes getroffen, welche nicht nur die Gesamtgenauigkeit einer Klassifikation wiedergeben, sondern ebenfalls einen Vergleich zwischen den Klassen, ebenso wie eine klassenspezifische Betrachtungsweise erlauben.

Tabelle 6: Schema einer Konfusionsmatrix

	Referenz	
Klassifiziert	Klasse 1	Klasse 2
Klasse 1	A	B
Klasse 2	C	D

Die schematische Matrix in Tabelle 6 zeigt die Relationen zwischen den Referenz – Daten, sowie den klassifizierten Werten. Dabei stehen die Buchstaben A – D für Häufigkeiten der jeweiligen Fälle. Beispielsweise würde A = 11 bedeuten, dass 11 räumliche Einheiten korrekt der Klasse 1 zugewiesen worden sind. Analog ist D für Klasse 2 zu interpretieren. Hingegen repräsentiert C die Häufigkeit, mit der Einheiten fälschlicherweise der Klasse 2 zugewiesen wurden. Dies würde einer Unterschätzung der Klasse 1 entsprechen. Dementgegen steht der Wert von B, welcher einer Überschätzung von Klasse 1 gleichzusetzen ist. Aufbauend auf diesem Schema werden hier folgende drei Indizes genutzt (Altman und Bland 1994a; Altman und Bland 1994b; Kuhn 2008):

$$\text{Sensitivity (True Positive Rate)} = A / (A + C)$$

$$\text{Specificity (True Negative Rate)} = D / (B + D)$$

$$\text{Balanced Accuracy} = (\text{Sensitivity} + \text{Specificity}) / 2$$

Der erste Indikator, Sensitivity, stellt die Anzahl der korrekt klassifizierten Einheiten, beispielsweise Pixel, der Klasse 1 der Gesamtzahl an Pixeln dieser Klasse (entsprechend der Referenz) gegenüber. Aufgrund der mathematischen Formulierung wird der Wert kleiner, sofern die Anzahl der falsch klassifizierten Pixel zunimmt. Hingegen beschreibt Specificity das Verhältnis der korrekterweise Klasse 2 zugeordneten Pixel

zur Gesamtzahl aller klassifizierten Pixel der Klasse 2. Mit Blick auf Klasse wären dies True Negatives, d.h. jene Pixel, die korrekterweise nicht Klasse 1 zugeordnet worden sind. Balanced Accuracy geht einen Schritt weiter und setzt die beiden genannten Indizes in Bezug zueinander. Der entsprechende Wert wird größer, wenn die Anzahl der korrekt klassifizierten Pixel über beide Klassen zunehmen.

Für die folgenden Kapitel gelten die Konventionen:

- Sensitivity wird als **TPR** bezeichnet und
- Specificity wird als **TNR** bezeichnet

Mit Blick auf Tabelle 6 gilt zu beachten, dass hier ein zwei-Klassen – Problem dargestellt ist, wobei sich die genannten Indizes auf eine einzelne Klasse beziehen. So können einer Klasse sowohl True Positives, wie auch True Negatives zugewiesen werden. Jedoch ist das Schema ohne Probleme auf Mehr-Klassen – Probleme anwendbar. Dabei entspricht Klasse 1 der aktuell betrachteten Klasse und Klasse 2 steht stellvertretend für sämtliche weitere Klassen.




Abbildung 14: Balanced Accuracy – Varianten 1 bis 4

Abbildung 14 zeigt Werte der Balanced Accuracy für die ersten vier Varianten. Zu beachten ist, dass für die 3te und 4te Klasse jeweils Klasse 12 und 13 den Klassen 11,

bzw. 13 zugerechnet wurde (siehe Tabelle 2). Zeigen fast alle Konstellationen hohe Werte, gibt es doch einige Auffälligkeiten:

- Klassen 12 und 13 weisen deutlich geminderte Werte gegenüber allen weiteren Varianten und Klassen auf
- Bei den Varianten 1 und 2 fällt auf, dass mit Blick auf die Klassen 11 und 21 in Relation zu den Varianten 3 und 4 niedrigere Werte erzielt wurden. Dabei scheinen sich die relativen Unterschiede pro Klasse zwischen den Varianten analog zu verhalten
- Die Werte für die Klassen 31 und 32 stellen sich im Vergleich zu nahezu allen anderen Klassen etwas niedriger dar
- Über alle Klassen hinweg zeigt sich ein Gefälle zwischen den Varianten 1 und 3 einerseits, sowie 2 und 4 andererseits.
- Eine Ausnahme bildet Klasse 40, wobei hier keine Unterschiede zwischen den Varianten ausgemacht werden können




Abbildung 15: TPR – Varianten 1 bis 4

Bei Betrachtung von Abbildung 15 fallen die Klassen 12 und 13 ebenfalls ins Auge. Dabei beträgt der Anteil an korrekt zugewiesenen Klassen jeweils nur rund 35%, bzw. 50%. Für die Klassen 31 und 32 sinkt die TP – Rate im Vergleich zu den anderen Klassen. Jedoch bleibt auch mit Blick auf die TPR festzuhalten, dass über alle Konstellationen hinweg die Varianten 2 und 4 deutlich besser abschneiden, als 1 und 3. Dabei zeigt sich dieser Unterschied im Falle von Klasse 21 besonders deutlich.




Abbildung 16: TNR - Varianten 1 bis 4

Im Gegensatz zur TPR weist die TNR keine vergleichbaren absoluten Unterschiede auf (Abbildung 16). Dies bezieht sich zum einen auf die Unterschiede zwischen den Klassen, wie auch zwischen den Varianten. Jedoch sind die vorhandenen relativen Unterschiede vergleichbar mit Abbildung 15. Ebenfalls ist der generelle Trend, dass Varianten 2 und 4 über alle Klassen hinweg die höchsten Werte aufweisen auch hier vorhanden. TPR und TNR zusammengefasst lässt sich bis zu dieser Stelle festhalten, dass erheblich weniger Klassen über-, als unterschätzt werden.

Im Vergleich zu Abbildung 14 kann mit Blick auf Abbildung 17 eine deutlich höhere Variabilität ausgemacht werden. Beim ersten Blick auf die Grafik fallen die durchgehend hohen Werte der Varianten 5 und 8 auf. Diese ziehen sich über alle Klassen und haben durchgehend Werte über 90%. Lediglich die Klassen 31 und 32 fallen durch

leicht niedrigere Werte im Vergleich zu den übrigen Klassen auf. Die mit Abstand schlechteste Variante über alle Klassen ist Variante 6.




Abbildung 17: Balanced Accuracy - Varianten 5 bis 9

Hier bildet die Klasse 22 eine Ausnahme, wobei ein Wert von rund 80% erreicht wird. Für die Varianten 5 und 8, sowie 7 und 9 können über alle Klassen relativ gesehen dieselben Unterschiede zueinander abgelesen werden. Auf Klassenebene markieren die Werte der Klasse 40 einen ganz erheblichen Unterschied zu den im Vorfeld beschriebenen vier Varianten. Zwar werden ebenfalls Werte um 100% erreicht, aber gleichsam schaffen es zwei Varianten (6 und 9) gerade auf 50%.

In Abbildung 18 sind die TR – Raten der Varianten 5 bis 9 aufgezeigt. Analog zur vorherigen Abbildung fallen die Varianten 5 und 8 auf, welche im Vergleich zu den anderen untersuchten Varianten deutlich höhere Werte für TPR aufweisen. Lediglich Klasse 31 bildet einen markanten Ausreißer, wobei hier die Rate unter 90% fällt. Hier muss also eine erhebliche Unterschätzung dieser Klasse zugrunde liegen. Im Gegensatz zur Abbildung 15 fällt hier auf, dass die Varianten 6 und 9 einen durchaus ähnlichen Verlauf über alle Klassen zeigen.




Abbildung 18: TPR - Varianten 5 bis 9

Die mit Abstand größten Unterschiede zeigen sich bei Klasse 11 mit ca. 25% Punkten, sowie bei Klasse 31 mit ca. 15% Punkten. Für Klasse 40 kann hier die Ursache für die schlechten Werte der Balance Accuracy ausgemacht werden: die Klassen 6 und 9 wurden demnach sehr stark unterschätzt, was sich in Werten (TPR) unter 10% ausdrückt. Zu erwähnen bleiben ebenfalls die Klassen 31 und 32 für die Variante 7: hier wurden jeweils gerade etwas mehr als 40% der betrachteten Samples erkannt, was ebenfalls für eine erhebliche Unterschätzung dieser Klassen spricht.

Abbildung 19 zeigt, ganz im Gegensatz zu Abbildung 16 erhebliche Variationen der jeweiligen Werte. Beim ersten Blick fällt auf, dass die Variationen 5 und 8 über alle Klassen nahezu 100% TNR aufweisen. Dementsprechend gibt es bei diesen Klassen, bzw. Varianten kaum Überschätzung. Lediglich im Falle von Klasse 32 ist ein kleiner Abbruch um ca. 2% Punkte zu verzeichnen. Die größten Unterschiede zwischen den Variationen weisen die Klassen 21 und 31 auf. Dabei auffällig ist der relativ gleiche Verlauf der Kurven für diese beiden Klassen. So unterscheiden sich die TNR – Werte der Varianten 6, 7 und 9 für diese beiden Klassen relativ im selben Maße.




Abbildung 19: TNR - Varianten 5 bis 9

Lediglich Klasse 21 bildet hier für Variante 7 eine Ausnahme im absoluten Wertebereich, wobei dennoch die relativen Beziehungen zueinander erhalten bleiben. Alles in allem kann an dieser Stelle festgehalten werden, dass sich die Überschätzungen der vorliegenden Varianten teils erheblich von den in Abbildung 16 gezeigten unterscheiden, bzw. diese erheblich übertreffen. Dies gilt insbesondere für die Klassen 21 und 31.

Im Folgenden wird lediglich jene Konfusionsmatrix von Variante 4 detailliert beschrieben, da diese die mit Abstand besten Ergebnisse hinsichtlich der erreichten Genauigkeit erzielt hat. Die entsprechend detaillierten Beschreibungen der übrigen Varianten finden sich im Anhang A1.

Tabelle 7: Konfusionsmatrix - Variante 4

		Referenz					
		11	21	22	31	32	40
Klassifiziert	11	1001	3	0	1	1	0
	21	20	1091	0	0	0	0
	22	0	0	1047	0	2	0
	31	0	0	5	950	44	0
	32	0	0	1	78	966	0
	40	0	0	0	0	0	468

Tabelle 7 stellt die Konfusionsmatrix von Variante 4 dar. Dabei zeigt sich, dass Klasse 11 um 20 Samples zugunsten von Klasse 21 unterschätzt wurde. Ebenso ist die Trennung der Klassen 31, bzw. 32 mit Problemen behaftet. So wurde Klasse 31 um 78 Samples, sowie Klasse 32 um 44 Samples unterschätzt. Bei den Klassen 21 und 22 sind weitere Fehlklassifikationen zu finden, wobei diese mit Verweis auf die Gesamtzahl der hier betrachteten Samples marginal sind. Ein fehlerfreies Bild zeigt sich mit Blick auf Klasse 40, wobei hier sämtliche Samples korrekt klassifiziert worden sind. Über alle Klassen hinweg zeichnet sich ab, dass die Klassifikation basierend auf Variante 4 überaus gute Ergebnisse erzielt. Lediglich ein sehr geringer Anteil der zur Validierung genutzten Samples wurde falsch klassifiziert.

3.1.6. Schlussfolgerungen für die Gesamtszene

Mit Verweis auf die oben beschriebenen Ergebnisse der Testphase können mit Blick auf die Landbedeckungsklassifikation für ganz Baden – Württemberg folgende Schlüsse gezogen werden:

- Klassifikationen, welche GLCM verwendet haben, schneiden grundsätzlich besser ab, als jene, die keine Information über Texturen genutzt haben
- Die Variationen des Klassenschemas haben gezeigt, dass die Klassen 12 und 13, zumindest im Kontext der hier erstellen Samples, zu drastisch verminderten Genauigkeiten führen. Findet eine Aggregation der Klassen statt, erhöht sich die Genauigkeit entsprechend
- Im Falle der variierten Daten für Training und Validierung fallen vier Varianten ins Auge, welche überaus gute Genauigkeiten erzielt haben. Dies sind die Varianten 5 und 8. Anzumerken sind hier dennoch zwei wesentliche Punkte: im Falle von Variation 5 wurden Ref – Daten zur Validierung genutzt (siehe Tabelle 6). Die vorhandene Unterschätzung bei Klasse 31 deutet darauf hin, dass die COR / Cop – Daten für Siedlungsbereiche keine ausreichenden Informationen zum Trainieren des Modells liefern. Mit Blick auf Variante 8 ist zu vermerken, dass die Daten zur Validierung aus zwei Komponenten bestehen: die thematische Komponente aus den COR / Cop – Daten, sowie die Lage aus den Ref – Daten. Betrachtet man jene Varianten, welche ausschließlich COR 7 Cop –

Daten zum Trainieren und Validieren genutzt haben, so fallen die deutlich schlechteren Genauigkeiten auf. Eine Ausnahme hiervon stellt lediglich Klasse 22 dar.

Somit ist auf Basis der hier gerechneten Tests der Rückschluss zu ziehen, dass eine Kombination aus Ref-, sowie COR / Cop – Daten zur Klassifikation unzureichende Genauigkeiten liefern. Weiterhin scheint sich die alleinige Nutzung von COR / Cop – Daten für Training und Validierung ebenfalls nicht zu eignen.

Als Konsequenz dieser Ausführungen wird Variation 4 auf die Gesamtszene von Baden – Württemberg angewandt. Die entsprechende Klassifikation wird im Folgenden genauer beschrieben.

3.2. Phase 2 – Klassifikation der Gesamtszene

3.2.1. Klassenschema und Sampling

Für die Klassifikation der Gesamtszene von Baden – Württemberg wurden auf Basis visueller Bildinterpretation der Sentinel-2 – Szene neue Samples erstellt (Tabelle 8).

Tabelle 8: Samples für Gesamtszene

	Klasse					
Samples	11	21	22	31	32	40
Anzahl (Gesamt)	1283	1533	2320	1852	1070	121
Anzahl (Training)	419	520	774	618	361	36
Anzahl (Validierung)	864	1013	1546	1234	709	85

Die Klassifikation selbst basiert, entsprechend Variante 4 des vorherigen Kapitels, auf insgesamt 40 Informationskanälen. Diese setzen sich zusammen aus 5 Sentinel – Bändern (2, 3, 4, 7, 8), sowie jeweils 7 Textur – Indizes.

Hinsichtlich der Samples aus Tabelle 8 wurde eine 1/3 – 2/3 – Unterteilung für Training, bzw. Validierung vorgenommen. Abbildung 20 zeigt hierfür die Anzahl der jeweiligen Training – Samples pro Klasse. Hierbei stechen zwei Klassen hervor: 22 und 40. Hintergrund dafür ist im Falle von Klasse 22 die Tatsache, dass die zugrundeliegende Szene Mitte August aufgenommen worden ist. Entsprechend gab es eine große Anzahl brachliegender Ackerflächen. Für Klasse 40 ergibt sich die geringe Anzahl an Samples aus der Tatsache, dass es nur wenige Wasserflächen in Baden – Württemberg gibt. Die vorhandenen Flächen repräsentieren meist Flussläufe, wie Rhein oder Donau, selten auch kleinere Baggerseen.




Abbildung 20: Anzahl der Training - Samples pro Klasse

Abbildung 21 zeigt ergänzend die Flächenverteilung der Training – Samples in Abhängigkeit der jeweiligen Klasse. Dabei fällt gerade mit Blick auf Klasse 22 die eher geringe mittlere Fläche von 25000m² auf. Dies relativiert die obige Anzahl teilweise, da zwar mehr, dafür aber kleinere Flächen erstellt wurden. Dementgegen stehen die Klassen 11 und 40. Die überaus große mittlere Fläche der Waldgebiete gründet sich vor allem aus den in Baden – Württemberg bestehenden großen Waldflächen, wie beispielsweise Schwarzwald, oder auch Wälder der schwäbischen Alb. Die Wasserflächen hingegen repräsentieren größere zusammenhängend erstellte Flächen entlang eines Flusslaufes, um eine repräsentative Grundgesamtheit der zugrundeliegenden spektralen und textuellen Information bereitzustellen. Der größte Unterschied zwischen Anzahl und mittlerer Fläche findet sich im Falle der Wohngebiete. Hier zeigt sich die meist kleinräumige Struktur der erstellten Samples, wobei mit der gleichzeitig hohen Anzahl ebenfalls ein möglichst hoher Grad an Repräsentativität erreicht werden soll.




Abbildung 21: Mittlere Flächengrößen der Training - Samples pro Klasse

Mit Verweis auf Kapitel II soll hier nochmals darauf eingegangen werden, wie mit den fehlenden Bildinformationen im östlichen Teil von Baden – Württemberg umgegangen wurde. Um eine mögliche Fehlklassifikation zu vermeiden, wurden sämtliche Datensätze auf Basis einer Maske, welche jene Bereiche mit Bildinformation umfasst, verschnitten. Da jedoch die räumliche Ausdehnung der verwendeten Daten, insbesondere der rasterbasierten, lediglich eine quadratische Form definieren kann, wurden die entsprechenden Pixel, welche keinerlei Information enthalten, auf „0“ gesetzt. Weiterhin wurden im Rahmen des Sampling – Verfahrens (s.o.) diese Bildregionen ausgespart. Demnach basiert das errechnete Klassifikationsmodell, sowie die Validierung ausschließlich auf Bereichen, welche Informationen beinhalten.

3.2.2. Phase 2 – Ergebnisse

Abbildung 22 gibt einen Überblick über die klassifizierte Gesamtszene (Teilbild a). Auffällig ist hierbei die als Wasser klassifizierte Fläche im rechten Bildbereich. Wie oben bereits angesprochen, repräsentiert diese Fläche jene Bildbereiche, die keinerlei

Information (bezüglich Sentinel-2) enthalten. Die folgenden Analysen, sowie statistische Darstellungen beziehen sich entsprechend explizit nicht auf diese Bildregion.

Wechselt man den Maßstab und betrachtet eine einzelne Gemeinde (Teilbild c), so fällt die feine Differenzierung zwischen Wohn- und Industrieflächen ins Auge. In diesem Fall bildet die Stadt Tübingen das Zentrum des Bildes, wobei ebenfalls große Straßenzüge klassifiziert werden konnten. Diese fallen jedoch den Klassen der Industrie- und Wohnflächen zu, da keine explizite Klasse für Straßenflächen erstellt worden ist. Ebenso ist eine klare Differenzierung zwischen brachliegenden und bewirtschafteten Äckern, sowie Wiesen zu erkennen.

Haben die obigen Beschreibungen rein qualitativen Charakter, so lassen sich auf Basis verschiedener räumlicher Aggregationsebenen weitere, mehr quantitative Maße auf Basis der erstellten Klassifikation ableiten. Im Folgenden geschieht dies unter Nutzung von Verwaltungsebenen als Form der räumlichen Aggregation (Abbildungen 23 bis 28). Der Fokus liegt dabei auf der Betrachtung der klassenbezogenen Flächenanteile pro Verwaltungseinheit.

Abbildung 23 zeigt die Flächenanteile auf Basis der Gemeinden. Dargestellt sind die Flächenanteile einer Klasse in Relation zur Gesamtfläche einer Gemeinde.

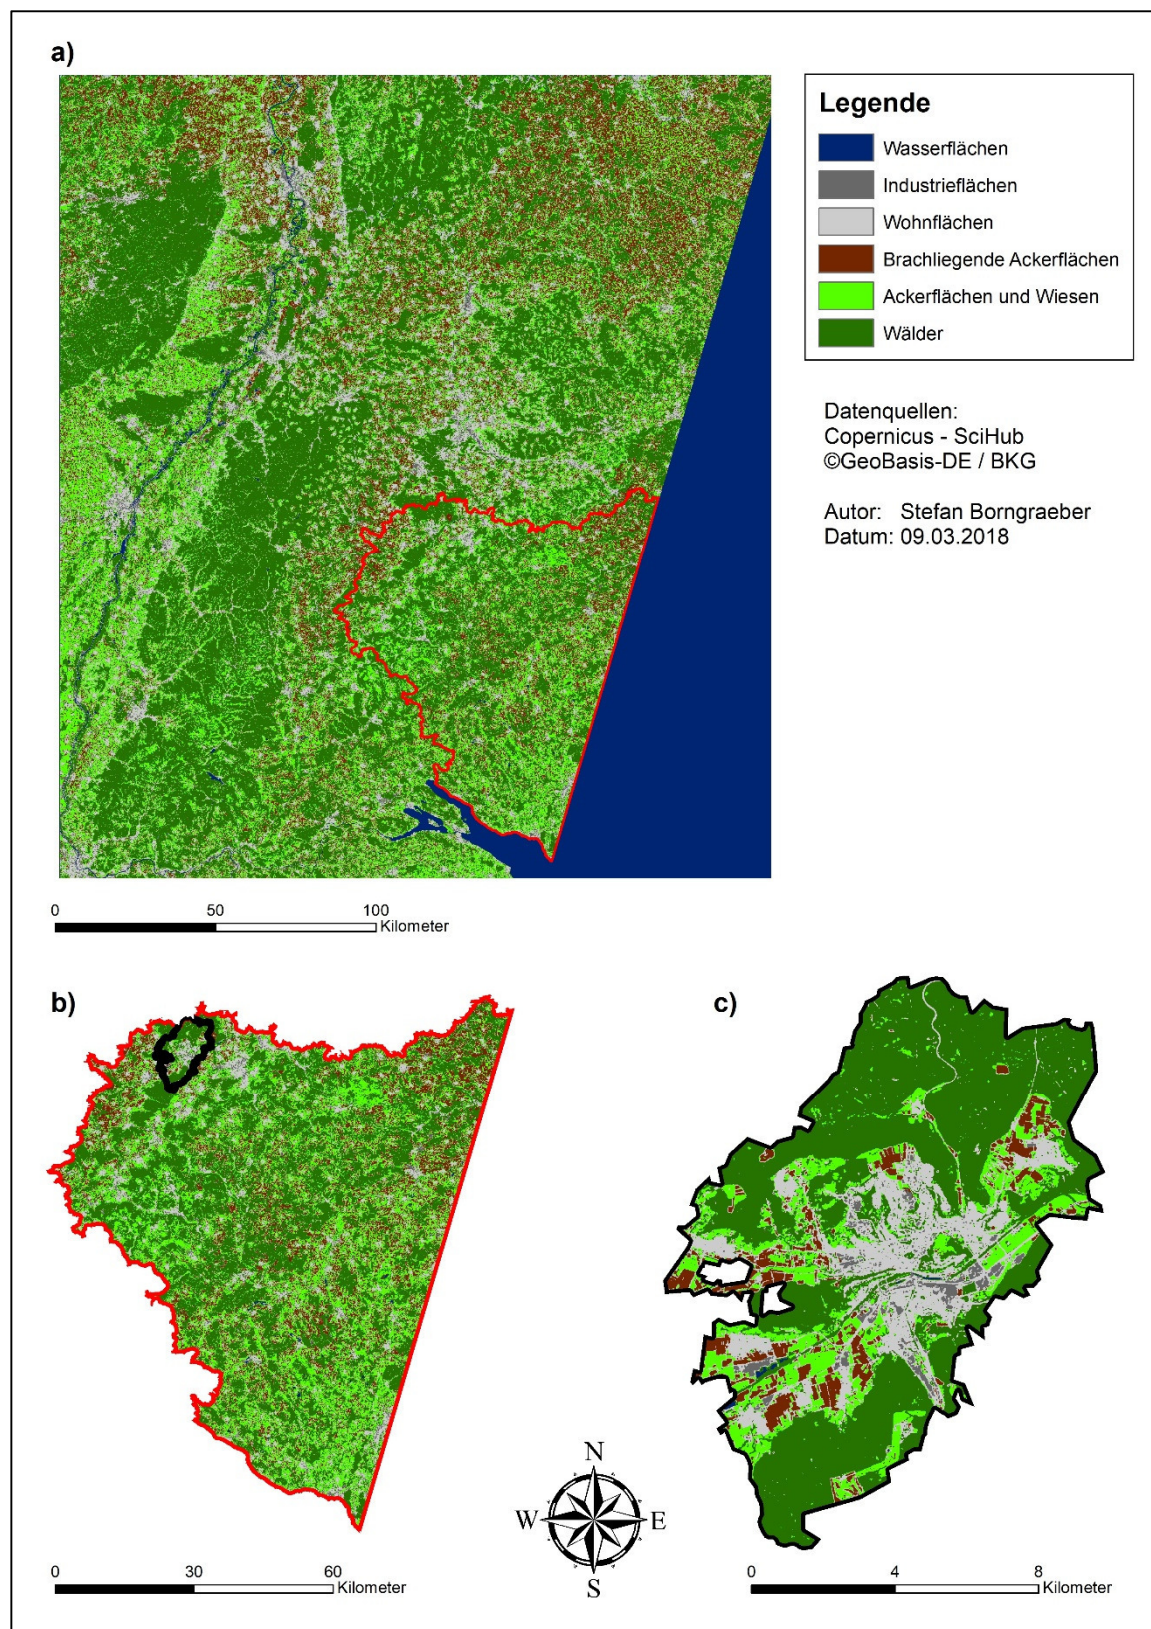


Abbildung 22: Abbildung 23: Klassifikation der Landbedeckung - Übersicht

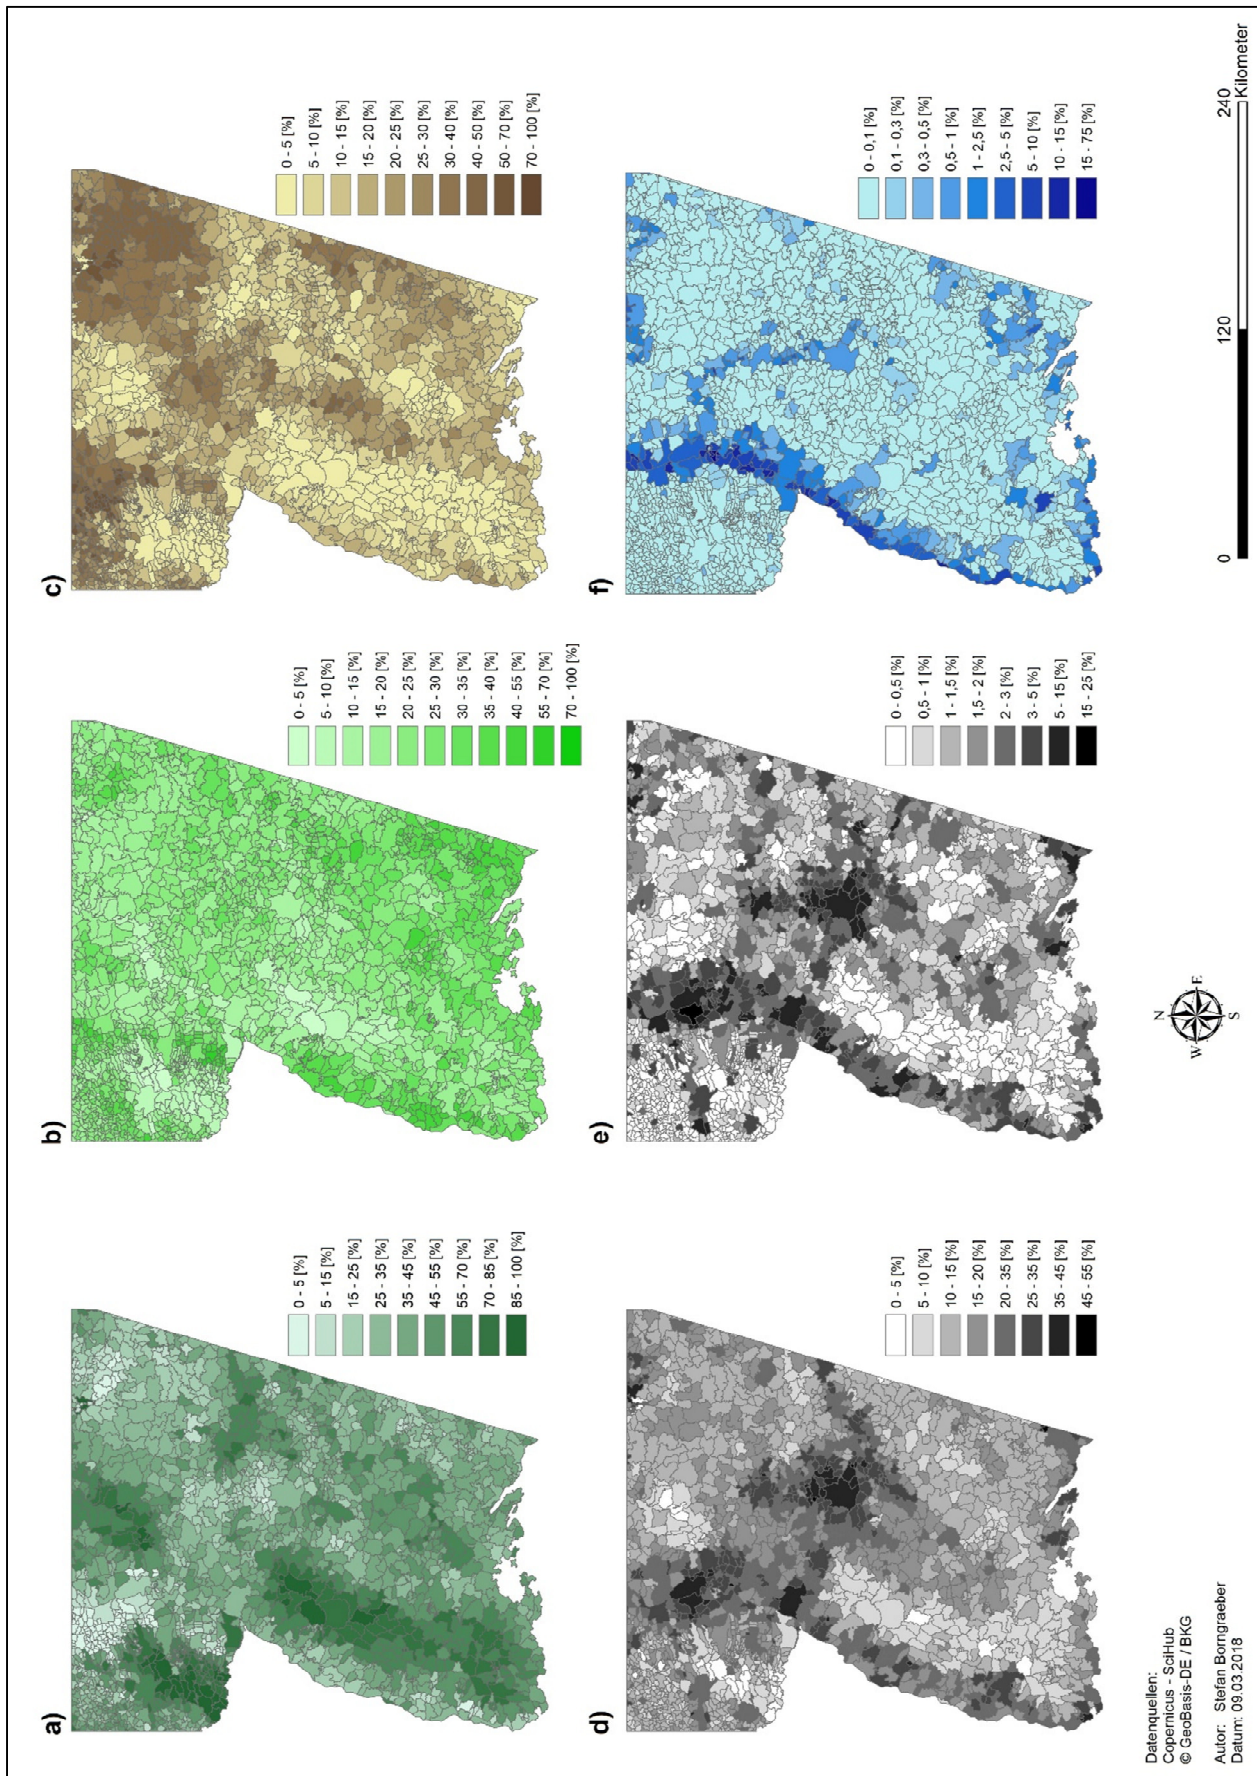


Abbildung 23: Flächenanteile der Klassen pro Gemeinde; a) Wälder, b) Äcker und Wiesen, c) brachliegende Äcker, d) Wohnflächen, e) Industrieflächen, f) Wasserflächen

Die Skalierung der Anteile wurde an die jeweilige Klasse angepasst. Somit wurde keine einheitliche Skalierung über alle Klassen gewählt, um eine adäquate Darstellung zu ermöglichen.

Beachtet werden muss für Abbildung 23, vor allem mit Blick auf die Teilbilder a) bis c), dass Werte bis zu 100% vorkommen können. In diesen wenigen Fällen handelt es sich nicht um eine tatsächliche Landbedeckung der jeweiligen Klasse von 100%, sondern es handelt sich vielmehr um diejenigen Randbereiche im rechten Bildteil, die im Zuge des Verschneidens mit der Ausdehnung der Sattelitenszene fragmentiert wurden. Somit kommen in den hier betrachteten Daten nur Teile der jeweiligen Gemeinden vor, da für deren restlichen Bereiche keine Klassifikation vorliegt. Trotz dieses Umstandes werden auch diese Gemeinden hier miteinbezogen, da der Flächenanteil für die gezeigten Bereiche korrekt ist. Dabei wurde nicht die tatsächliche Gesamtfläche der jeweiligen Gemeinden als Relation genutzt, sondern lediglich die Fläche des Fragmentes.

Ebenfalls, wie bereits im Falle der Übersicht von Abbildung 22, lassen sich hier größere landschaftliche Merkmale ablesen, wie beispielsweise die hohen Flächenanteile von Wäldern in Bereichen des Schwarzwaldes. Mit Blick auf Wohn- und Industrieflächen fällt abermals Stuttgart auf, wobei hier mit die höchsten Flächenanteile dieser beiden Klassen erreicht werden. Basierend auf Teilbild b) können zudem Bereiche des Weinbaus ausgemacht werden, welche sich entlang des Rheins, bzw. des Oberrheingrabens mit N – S – Verlauf erstrecken, wie auch Bereiche landwirtschaftlicher Nutzung entlang der jeweiligen Flusstäler. Besonders zeigen sich die Flächenanteile der Klasse Wasser in Teilbild f): hier zeichnen sich überaus deutlich die Flussverläufe von Rhein und Neckar nach. Durch die in beiden Fällen intensive Begradigung der Flussläufe und der damit oft einhergehenden Errichtung von Stauwerken können hier hohe Flächenanteile der jeweiligen Gemeinden erreicht werden. Weitere hohe Anteile des Wassers sind auf einzelne Seen zurückzuführen, wie beispielsweise Baggerseen. Für das in Abbildung 22 gezeigte Beispiel der Gemeinde Tübingen lautet die relative Flächenaufteilung wie folgt:

Wälder (55,67%), Wohnflächen (19,86%), Ackerflächen und Wiesen (14,78%), brachliegendes Ackerland (7,38%), Industrieflächen (2,2%) und 0,14% an Wasserflächen.

Abbildung 24 zeigt die statistische Verteilung der Flächenanteile für jede Klasse in Relation zur Gemeindefläche. Wie schon im Vorigen herausgearbeitet, bildet die Klasse Wald bezüglich des Flächenanteils die Klasse mit den höchsten Werten. Gleichzeitig jedoch weist diese Klasse auch die größte Spannweite auf. Der Median liegt hier bei ca. 38%, wobei der Interquartilsabstand rund 20% beträgt. Ein anderes Bild zeigt sich im Falle von Äckern und Wiesen: Hier setzt der Median deutlich tiefer an (ca. 24%) und auch der Interquartilsabstand ist mit ca. 10% deutlich geringer. Gleiches gilt für die gesamte Spannweite, wobei die Ausreißer nach oben jene bereits angesprochenen Fragmente der Randbereiche repräsentieren. Interessant sind ebenso die Werte für Wohn- und Industrieflächen. Für Klasse 31 wurden immerhin Gemeinden klassifiziert, deren Fläche zu über 50% durch Wohnflächen geprägt sind. Im Falle der Industrieflächen sind die Unterschiede noch deutlicher.


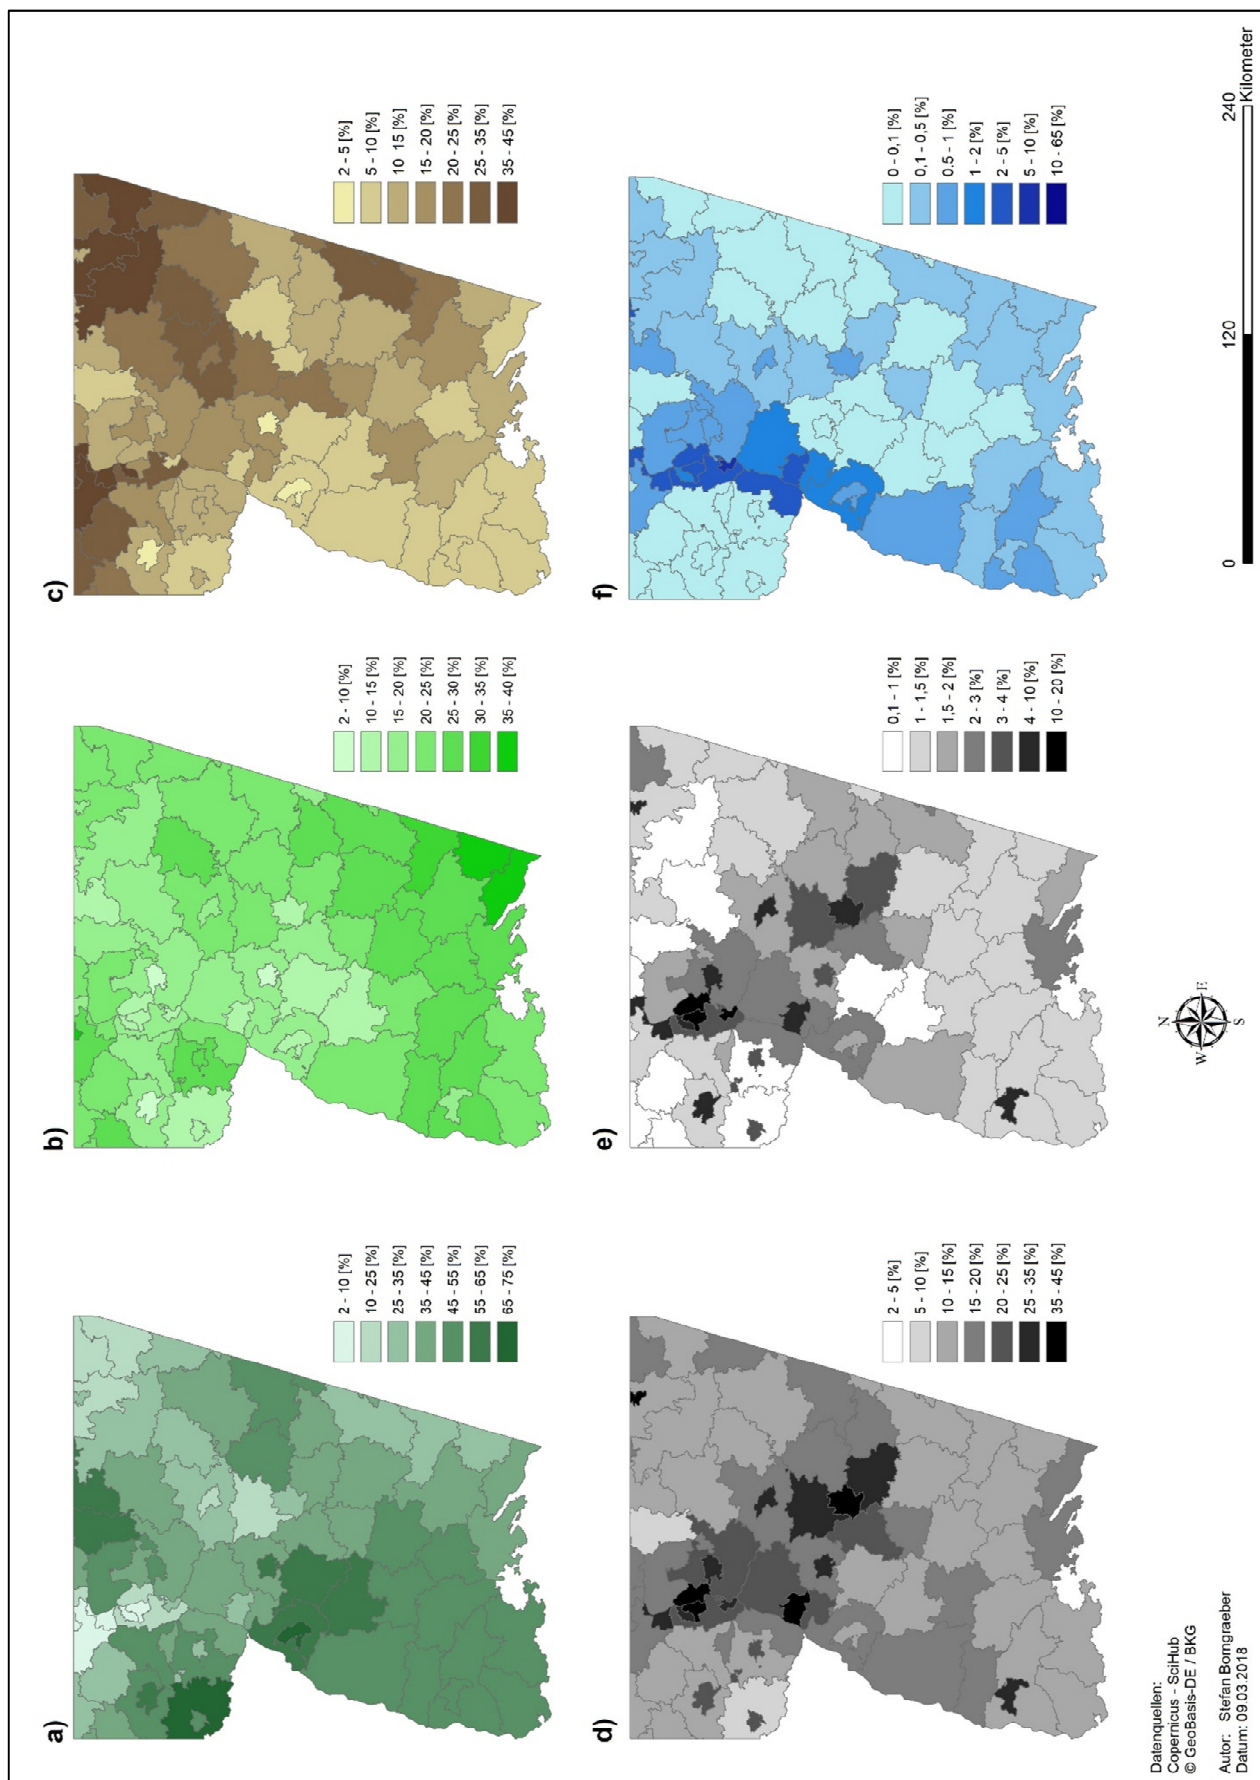


Abbildung 24: Statistische Verteilung der Flächenanteile auf Gemeindeebene

Bei einem sehr geringen Median (ca. 2%) und einem sehr kleinen Interquartilsabstand gibt es einige markante Ausreißer bis über 12% Flächenanteil. Die Statistik der Ausreißer ist für die Klasse 40 am deutlichsten ausgeprägt, wobei hier die meisten Gemeinden bei ca. 0% liegen. Die gezeigten Ausreißer geben jene Gemeinden wieder, die entweder große Flussläufe, wie Rhein und Neckar, oder aber Seen umfassen.

Abbildung 25 stellt Flächenanteile für die nächst höhere Aggregationsebene, den Landkreisen, dar. Im Vergleich zur Gemeindeebene fällt mit Blick auf die Klasse der Wälder auf, dass sich die bisher sich deutlich abgezeichneten landschaftlichen Merkmale auf Landkreisebene kaum mehr deutlich erkennen lassen. Zwar sind beispielsweise immer noch die stark bewaldeten Gebiete rund um den Schwarzwald auszumachen, jedoch ist dessen räumlicher Verlauf nicht mehr zu bestimmen. Hinsichtlich der Wohn- und Industrieflächen ergibt sich ein teilweise anderes Bild: hier sind auch weiterhin die stark verdichteten urbanen Bereiche deutlich zu erkennen. So sticht Freiburg im Südwesten ebenso wie Stuttgart in der Bildmitte, Karlsruhe im zentralen Westen und Mannheim / Ludwigshafen im Nordwesten heraus. Gleichfalls werden, im Falle der Industrieflächen, Landkreise deutlich hervorgehoben, welche, mit unter einem Prozent, nur einen sehr geringen Anteil dieser Landbedeckungsklasse aufweisen. Ein Vergleich zwischen Freiburg im Südwesten und Stuttgart macht deutlich, wie die beiden Städte hinsichtlich der Wohnflächen, sowie der Industrieflächen ins Umland eingebunden sind. Während Freiburg sowohl hinsichtlich der Anteile an Wohnflächen, wie auch an Industrieflächen mit Abstand die höchsten Werte gegenüber sämtlichen benachbarten Landkreisen aufweist, so ergibt sich im Bereich Stuttgart ein anderes Bild: hier scheint der Großteil der direkt benachbarten Landkreise in eine ähnliche Richtung zu tendieren, wie Stuttgart selbst. Zwar weist Stuttgart dennoch die höchsten Werte für beide Landbedeckungsklassen auf, jedoch ist der absolute Unterschied zu den Nachbarn sehr gering.

Ein besonderer Fall mit Blick auf die Skalierung stellt Klasse 40 dar (Teilbild f): aufgrund der sehr geringen Flächenanteile der meisten Landkreise wurde hier für den Bereich zwischen 0% und 1% ein feines Intervall gewählt, um dennoch Unterschiede zwischen Landkreisen darzustellen. Das oberste Intervall umfasst immerhin Werte zwischen 10% und 65%, wobei hier im Wesentlichen nur Mannheim wiedergegeben wird.



Aufgrund des hier verorteten Zusammenflusses von Neckar und Rhein ergibt sich ein vergleichsweise hoher Flächenanteil in diesem Bereich. Abgesehen davon kann mit dieser feinen Skalierung dennoch der Verlauf der beiden großen Flusssysteme von Rhein und Neckar im Groben wiedergegeben werden.




Abbildung 26: Statistische Verteilung der Flächenanteile auf Landkreisebene

Der Vergleich zwischen Abbildung 24 und Abbildung 26 zeigt, dass die relativen Beziehungen zwischen den Klassen erhalten bleiben. Dies liegt schlicht daran, dass beide Berechnungen auf Basis derselben Grundgesamtheit durchgeführt wurden. Lediglich die Aggregationsstufe ist im Falle von Abbildung 26 höher. Entsprechend macht an dieser Stelle eine vergleichende Betrachtung wenig Sinn, weshalb nun eine isolierte Analyse der Landkreise erfolgt. Klasse 11 weist eine hohe Spannweite auf, wobei der Median den Interquartilsabstand nahezu halbiert. 50% der Landkreise weisen nach Abbildung 26 gegenüber Wäldern einen Flächenanteil zwischen 35% und 49% auf. Nach oben und unten gibt es erhebliche Ausreißer, was wiederum jenen Landkreisen Rechnung trägt, welche in Bereichen der größeren Wälder Baden – Württembergs, wie Schwarzwald, Bereiche der Schwäbischen Alb, oder auch Odenwald, liegen. Klasse 21 weist eine eher ungleiche Verteilung, zumindest der zentralen 50% auf.

Gleiches gilt für Klasse 22. Die Ausreißer der Klassen 31 und 32 können, wie bereits oben beschrieben, einzelnen Städten mit hoher Siedlungsdichte, sowie einem erheblichen Anteil ansässiger Industrie erklärt werden. Im Falle der Wohnflächen herrscht zudem für die oberen 50% eine deutlich höhere Variabilität vor. Die Wasserflächen zeigen das gewohnte Bild. Der dargestellte Ausreißer wurde bereits oben angesprochen und repräsentiert die Gegend um Mannheim, welche aufgrund des Zusammenflusses von Neckar und Rhein größere Wasserflächen aufweist.

Abbildung 27 stellt die Flächenanteile in Relation zur höchsten Aggregationsstufe, den Regierungsbezirken, gegenüber.

Tabelle 9: Gegenüberstellung von relativen und absoluten Flächenanteilen

	Stuttgart (rel.)	Stuttgart (abs.)	Freiburg (rel.)	Freiburg (abs.)	Karlsruhe (rel.)	Karlsruhe (abs.)	Tübingen (rel.)	Tübingen (abs.)
Klasse 11	35,5%	3349km ²	49,3%	4613km ²	48,9%	3386km ²	38,6%	2512km ²
Klasse 21	22,2%	2098km ²	25,5%	2387km ²	16,1%	1116km ²	28,9%	1877km ²
Klasse 22	21,2%	1998km ²	8,8%	823km ²	14,0%	970km ²	16,7%	1084km ²
Klasse 31	18,7%	1758km ²	14,4%	1343km ²	17,9%	1240km ²	14,2%	925km ²
Klasse 32	2,0%	194km ²	1,5%	139km ²	2,2%	150km ²	1,4%	91km ²
Klasse 40	0,1%	11km ²	0,5%	45km ²	0,7%	51km ²	0,2%	10km ²

Da sich die Gesamtflächen der Regierungsbezirke deutlich unterscheiden, stellt Tabelle 9 die relativen Flächenanteile den absoluten gegenüber. Wie zu erwarten, beinhaltet Freiburg den größten Flächenanteil an Wäldern, wobei sich der Unterschied zu Karlsruhe lediglich auf rund 0,4% beläuft. Dieser marginale relative Unterschied drückt sich mit Blick auf Tabelle 9 im Absoluten mit ca. 1300km² wesentlich deutlicher aus. Tübingen hingegen umfasst mit 28,9% den größten Anteil an Äckern und Wiesen, gefolgt von Freiburg, mit 25,5%, was einem absoluten Unterschied von rund 500km² entspricht. Im Falle der brachliegenden Ackerflächen führt mit 21,2% Stuttgart. Tübingen mit 16,7% weist den zweitgrößten Flächenanteil dieser Klasse auf. Die entsprechend absolute Differenz beträgt ca. 900km². Den größten Flächenanteil an Wohnflächen birgt Stuttgart mit 14,2%, gefolgt von Karlsruhe mit 17,9%. Der dazugehörige absolute Unterschied beträgt rund 500km². Für die Klasse der Industrieflächen stellt Karlsruhe denjenigen Regierungsbezirk mit dem höchsten Anteil dar (2,2%). Der absolute Unterschied beträgt hier ca. 45km². Mit 0,7% hat Karlsruhe Anteil an Wasserflächen, wobei Freiburg mit 0,5% an zweiter Stelle steht. Hier entspricht diese relative Differenz einem absoluten Wert von ca. 6km².

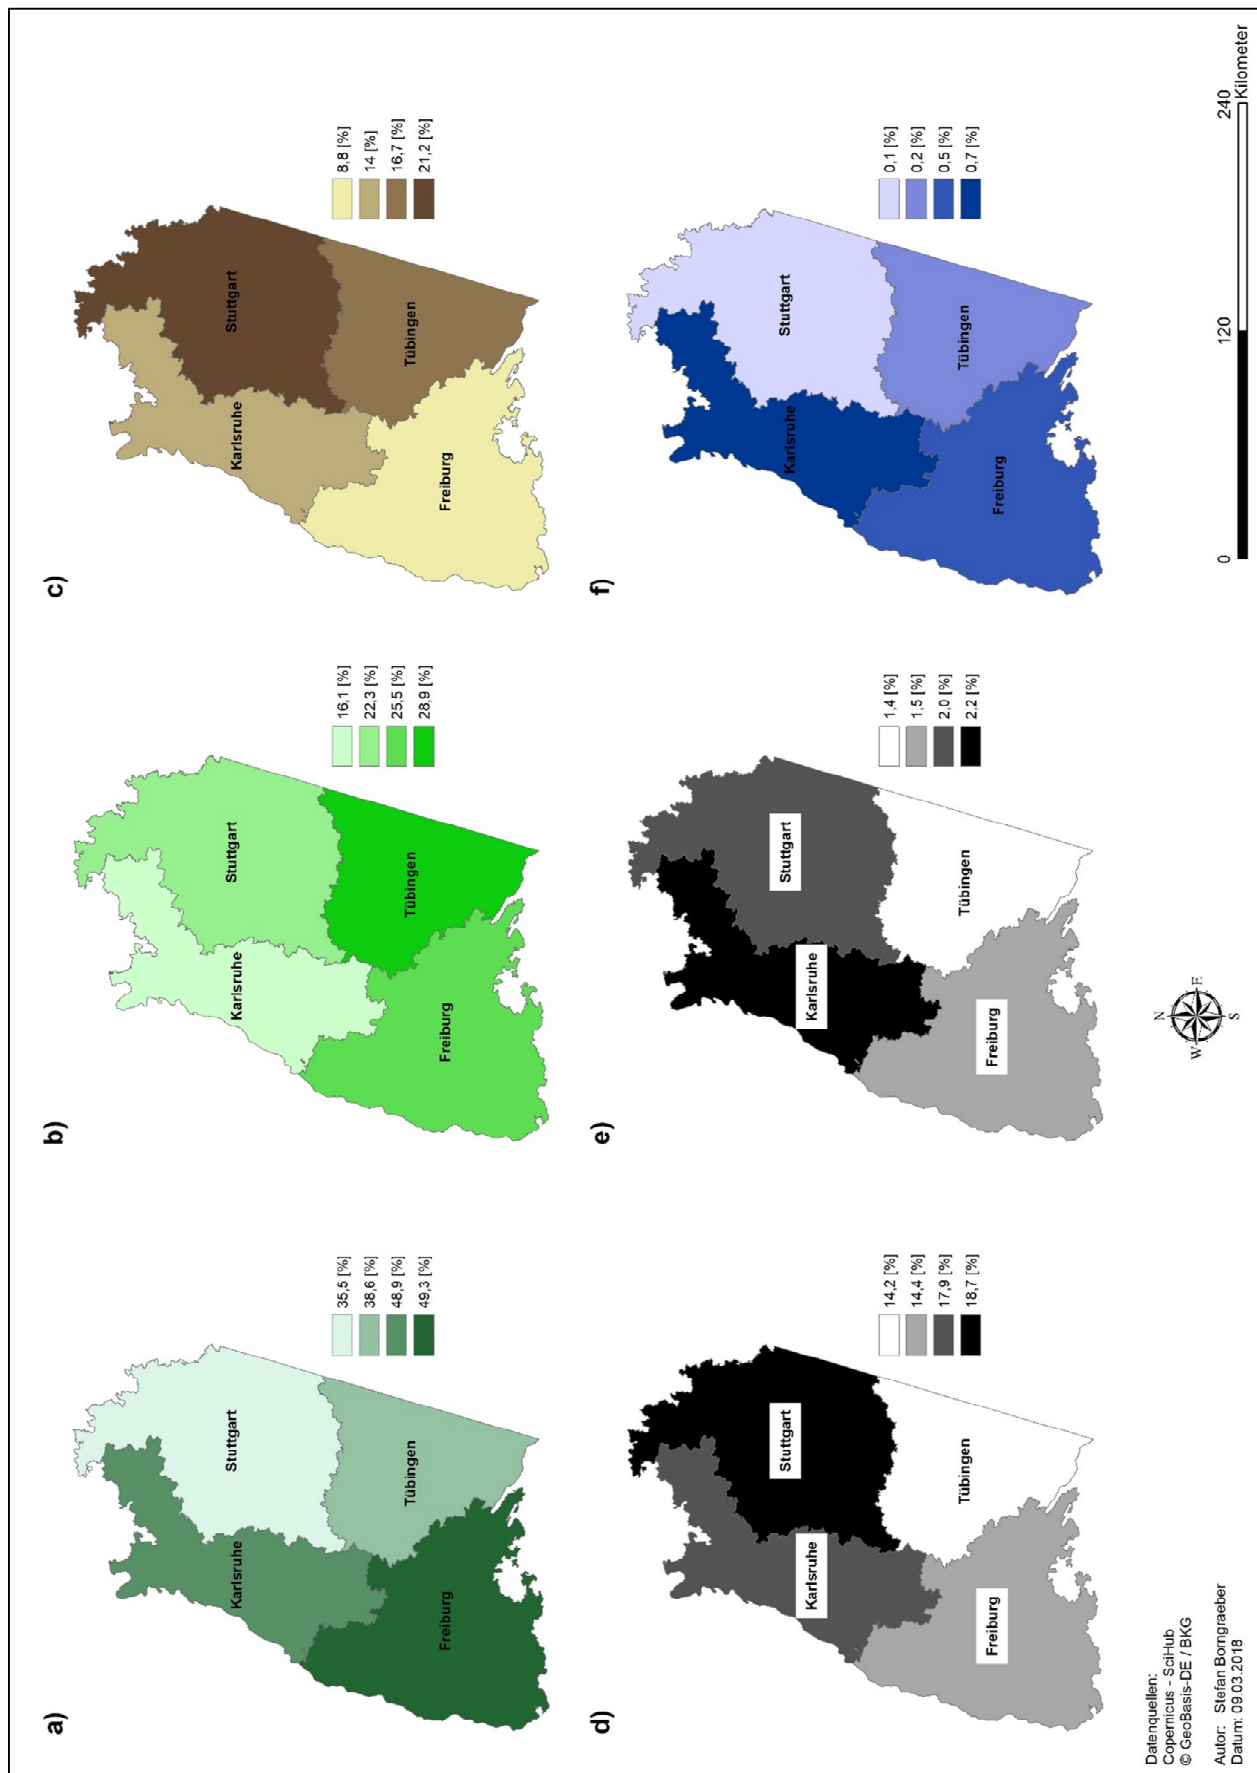


Abbildung 27: Flächenanteile der Klassen pro Gemeinde; a) Wälder, b) Äcker und Wiesen, c) brachliegende Äcker, d) Wohnflächen, e) Industrieflächen, f) Wasserflächen

Im Sinne der Vollständigkeit soll auch hier eine Betrachtung der statistischen Verteilung der jeweiligen Flächenanteile erfolgen (siehe Abbildung 28). Hierbei zeigt sich die größte Variabilität bei Klasse 11 mit einer Spannweite von ca. 23%. Die Klassen 21 und 22 weisen eine ähnliche Spannweite von ca. 13% auf, wobei sich hier die Interquartilsabstände, sowie die Lage des Medians unterscheiden. Dieser liegt, bei nahezu gleichem Interquartilsabstand bei ca. 23%, bzw. bei 16%. Ebenso bei rund 16% liegt der Median von Klasse 31, wobei diese Klasse eine deutlich geringere Variabilität aufweist. Die Klassen 32 und 40 repräsentieren die engsten Wertebereiche, wobei Klasse 32 mit einem Median von ca. 4% deutlich über den 1% von Klasse 40 liegt.




Abbildung 28: Statistische Verteilung der Flächenanteile auf Landkreisebene

Gerade mit Blick auf Klasse 32 wird der Effekt der Aggregation deutlich, war die Streuung der Gemeinden weitaus größer. So scheinen sich diese Unterschiede auf Gemeindeebene für die entsprechenden Regierungsbezirke zu egalisieren.

3.2.3. Phase 2 – Abschätzung der Genauigkeit

Wie bereits im Vorfeld angesprochen, wurde hier im Vergleich zu der beschriebenen Methodik in Kapitel 3.1.4 eine andere Vorgehensweise der Validierung gewählt. Der

Grund dafür liegt darin, dass zur Klassifikation der Gesamtszene nicht RStoolbox, sondern das RandomForest – Paket in R genutzt wurde (Breiman et al. 2018). Dieses Paket beinhaltet keine automatische Validierung, weswegen eine separate durchgeführt wurde.

Wie in Tabelle 8 beschrieben, wurden sämtliche Samples zu 1/3 dem Training und zu 2/3 der Validierung zugewiesen.




Abbildung 29: Verteilung der Klassen auf Samples zur Validierung

Abbildung 29 zeigt die Verteilung der Klassen innerhalb der Samples für die Validierung. Weil auch diese Daten im Vektorformat vorlagen, musste ein Sampling – Verfahren angewandt werden, um die im Rasterformat vorliegende Klassifikation mit den Referenzklassen der Samples zu verknüpfen. Basis dieses Verfahrens ist das erneute Sampling von Punkten innerhalb der Referenzpolygone. Als Methode des Samplings wurde regular gewählt, womit hier keine Zufallsvariable integriert wird. Nun wird an jeder Punktcoordinate zum einen der klassifizierte Wert auf Basis des Rasters ausgelesen und zum anderen die Referenzklasse auf Basis der Polygone. Als Mindestabstand des Samplings innerhalb der Polygone wurde 20m definiert, um ein mehrmaliges Sampling von Rasterzellen zu vermeiden. Aufgrund dessen, dass pro Polygon eine Vielzahl an Samples erstellt wird, erhöht sich die Grundgesamtheit mit Blick auf die Genauigkeitsabschätzung.




Abbildung 30: mittlere Fläche der Referenz - Polygone

Die Anzahl der Samples pro Polygon kann in Relation zur mittleren Fläche (Abbildung 30) abgeschätzt werden, wobei Abweichungen durchaus möglich sind. Demnach sind für Klasse 11 deutlich mehr Punktdaten zu erwarten, wie beispielsweise für Klasse 21. Da aber dennoch für jede Klasse eine Mindestanzahl von 10000 Punkten vorab definiert wurde, besteht für jede Klasse eine ausreichende Grundgesamtheit, um eine korrekte Validierung durchzuführen.

Die Gesamtgenauigkeit der Klassifikation liegt bei 0,9974 und der Kappa – Indexwert bei 0,9961. Tabelle 10 zeigt zudem die dazugehörige Konfusionsmatrix. Die Gesamtzahl der hier erstellen Samples (Punkte) lag bei 420604.

Tabelle 10: Konfusionsmatrix für Gesamtszene

		Referenz					
		11	21	22	31	32	40
Klassifiziert	11	223887	158	0	0	0	0
	21	263	45915	0	0	0	0
	22	0	20	92734	7	128	0
	31	0	0	51	17386	211	0
	32	0	0	23	195	18962	0
	40	0	0	0	0	6	20658

Von 224150 Samples, die der Klasse 11 zufallen, wurden 158 der Klasse 21 zugeordnet, d.h. hier fand eine minimale Überschätzung statt. Gleichzeitig wurden 263 nicht erkannt und fälschlicherweise Klasse 21 zugeteilt. Zwischen den Klassen 21 und 22 kam es auch zu leichten Überschätzungen der bewirtschafteten Flächen und Wiesen. Die größte Unterschätzung für Klasse 22 rührt von Fehlklassifikationen der Klassen 31 und 32. Auch zwischen diesen beiden Klassen gibt es einige Samples, welche der jeweils falschen Klasse zugeordnet worden sind. Die Klasse 40 erreicht nahezu 100%, lediglich 6 Samples wurden hier zugunsten der Klasse 32 überschätzt.




Abbildung 31: TPR, TNR und Balanced Accuracy für Gesamtszene

Abbildung 31 stellt nochmals die Ergebnisse für TPR, TNR und Balanced Accuracy für die Klassifikation der Gesamtszene dar. Am auffälligsten ist die Unterschätzung von Klasse 32, wobei ebenfalls Klasse 31 leicht unterschätzt wurde. Für beide Klassen ist die Balanced Accuracy auch entsprechend niedriger als bei den weiteren Klassen. Die TNR ist für alle Klassen nahe 100%, was für eine kaum vorhandene Überschätzung der einzelnen Klassen spricht.

Generell kann hier also von einer durchaus akzeptablen Klassifikation gesprochen werden, welche nun im Weiteren zur Ableitung des Wärmebedarfs von

Wohngebäuden herangezogen wird. Selbstverständlich muss über die hier errechneten Genauigkeitsindizes diskutiert werden. Verschiedene Überlegungen dazu finden sich im Kapitel 6.

4. Klassifikation des Wärmebedarfs für Wohngebäude

Im Kontext dieser Klassifikation ändert sich die räumliche Bezugsebene. Wurde in den vorherigen Kapitel die Klassifikation auf Pixel – Ebene beschrieben, so rückt nun die Klassifikation einzelner Gebäude in den Fokus. Diese Klassifikation dient der Differenzierung zweier gebäudescharfer Zielvariablen:

- **Gebäudetyp** - Hier kann basierend auf Loga et al. (2015) beispielsweise zwischen unterschiedlichen Größenklassen, wie Ein- oder Mehrfamilienhaus, oder auch zwischen verschiedenen Baualtersklassen differenziert werden
- **Wärmebedarf** – Die Wärmebedarfswerte basieren auf dem jeweiligen Gebäudetyp. Jedoch muss hier ein Konzept entwickelt werden, welches den Bezug zwischen den vorhandenen Daten und denen, die im Rahmen dieser Arbeit vorliegen, herstellt

Entsprechend dieser beiden Variablen gliedert sich das hier angewandte Konzept in zwei Teilbereiche. Zuerst wird eine Klassifikation der Gebäudetypen durchgeführt. In einem zweiten Schritt werden diese Typen als Grundlage zur Bestimmung der entsprechenden Wärmebedarfswerte herangezogen. Dabei erfolgt die Einbindung der bereits erstellten Klassifikation der Landbedeckung im Rahmen des ersten Teilbereiches. Die genauen methodischen Hintergründe werden im Folgenden erläutert.

4.1. Methodik zur Klassifikation der Gebäudetypen

Der generelle Ansatz der hier angewandten Methodik entspricht grundsätzlich jener, welche auch von Geiß et al. (2011) beschrieben wird. Somit steht hier die Verknüpfung einer Vielzahl verschiedener Daten und Parameter im Blickpunkt. Eine nachgeschaltete Evaluierung, zusammen mit einer Genauigkeitsabschätzung soll das Potenzial dieser Verknüpfung hinsichtlich der errechneten Wärmebedarfswerte für Wohngebäude herausarbeiten.

Die geometrische, bzw. räumliche Grundlage wird durch den hier genutzten LoD1 – Datensatz gegeben (siehe dazu Kapitel 2). Wie bereits in der Datenbeschreibung

dargelegt, umfasst dieser Datensatz sämtliche Gebäudeumrisse in Baden – Württemberg. Weiterhin sind Höhenwerte für jedes Gebäude verfügbar, welche jedoch stark geometrisch generalisiert worden sind. Dennoch werden auch diese genutzt, um Informationen der dritten Dimension mit in die Klassifikation einfließen lassen zu können.

4.1.1. **Aufbereitung der Gebäudedaten**

Da die Geometrien der Gebäudeumrisse hier als Grundlage für sämtliche Berechnungen dienen, muss dieser Schritt an erster Stelle durchgeführt werden.

Aufgrund der Tatsache, dass die Klassifikation der Landbedeckung lediglich eine räumliche Auflösung von 10m aufweist, ist zu erwarten, dass durch die oben beschriebene Selektion der Wohngebäude ebenfalls eine Vielzahl **kleiner Nebengebäude** selektiert wurde. Um die dazugehörigen Geometrien von den weiteren Berechnungen auszuschließen, wurde ein flächenbasierter Schwellwert von 50m² gesetzt. Gebäude, die eine geringere Grundfläche aufweisen, wurden aus dem Datensatz entfernt. Der gewählte Schwellwert richtet sich nach der Arbeit von Hecht (2014), wobei dieser eine tiefergehende Differenzierung nach freistehenden und nicht-freistehenden Nebengebäuden vorgenommen hat. Eine vergleichbare Differenzierung war jedoch für die vorliegende Arbeit nicht notwendig.

In einem zweiten Arbeitsschritt wurde eine **Aggregierung** mehrerer Gebäude zu einem Baublock, basierend auf einem Distanzschwellwert, vorgenommen. Entsprechend der Auflösung des LoD1 – Datensatzes wurde dieser Schwellwert auf 0,5m festgesetzt. Dies bedeutet, dass all jene Gebäude aggregiert werden, die weniger als 0,5m voneinander entfernt liegen. Der Hintergrund dieser Maßnahme richtet sich nach Wurm, Schmitt, und Taubenböck (2016) und hat im vorliegenden Kontext folgende Relevanz:

- Die Rechenzeit wird durch die Aggregierung deutlich verringert, da nicht jedes Gebäude einzeln klassifiziert werden muss. Dies gilt es insbesondere mit Blick auf die Klassifikation eines ganzen Bundeslandes zu beachten
- Da der Großteil der hier verfügbaren Kontextinformation in einer deutlich schlechteren räumlichen Auflösung vorliegt, ist der durch die Aggregierung zu erwartende Informationsverlust als gering anzusehen.

Da es jedoch gilt, gerade den zweiten Punkt zu untermauern, wurde im Folgenden mit zwei Datensätzen gerechnet: der eine beinhaltet sämtliche Einzelgebäude, der andere hingegen die aggregierten Gebäude.

4.1.2. Einbindung der Landbedeckungsklassifikation

Die Einbindung der **Information zur Landbedeckung** erfolgt auf zwei Arten.

Einerseits wird die Information genutzt, um jene Gebäude des LoD1 – Datensatzes zu selektieren, welche in Bereichen von Klasse 31 (Wohnflächen) liegen. Die zugrundeliegende Selektion basiert auf der Analyse der jeweiligen Lageziehungen, wobei eine räumliche Überschneidung der Datensätze zu einer positiven Selektion führt. Dies bedeutet, dass ein Gebäude immer dann ausgewählt wird, wenn es eine Überschneidung mit einer Wohnfläche aufweist. Hintergrund für diese Art der Einbindung ist v.a. die Differenzierung zwischen Landbedeckung und Landnutzung. So kann auf Basis der Sentinel-2 – Daten lediglich eine Klassifikation der Bedeckung stattfinden. Hingegen reichen die spektralen Informationen nicht aus, um Rückschlüsse auf die tatsächliche Nutzung der jeweiligen Gebäude zuzulassen. Zwar beinhaltet der LoD1 – Datensatz bereits detaillierte Informationen zu den Gebäuden, doch beziehen sich diese auf die Nutzung. Um eine konsistente Einbindung der satellitenbasierten Klassifikation zu ermöglichen, wurde die angesprochene Selektion vorgenommen. In der Konsequenz heißt dies, dass hier lediglich die Lage-, sowie die geometrische Information zu den Gebäuden genutzt wird. Die weiteren kontextuellen Daten des LoD1 – Datensatzes finden hier keine weitere Anwendung. Vielmehr basieren alle hier genutzten gebäudebezogenen Parameter auf eigenen Berechnungen.

Die zweite Art der Einbindung bezieht sich darauf, die Landbedeckung im räumlichen Kontext der Gebäude als zusätzliche Information zu nutzen. Gemeint ist die Berechnung des Flächenanteils der jeweiligen Landbedeckungsklasse in einem definierten Umkreis eines Gebäudes. Grundidee hierfür ist der Nutzen dieser zusätzlichen Information, um Gebäudetypen, insbesondere hinsichtlich deren Alter besser differenzieren zu können. Gerade für Neubaugebiete, welche außerhalb der Kernsiedlung liegen, könnte im nahen Umfeld eine andere Verteilung der Landbedeckung vorliegen als beispielsweise im Altstadtbereich.

Umgesetzt wurde dies nun mittels der Generierung von räumlichen Puffern mit einem Radius von 100m. Als Basisobjekte wurden jedoch nicht die Gebäude, sondern die Polygone des LBM-DE 2015 – Datensatzes genutzt, welcher u.a. eine Klasse „Bebauung“ (Schlüsselwert: B110; siehe Tabelle 1) enthält. Diese Baublöcke umschließen generell baulich geprägte Flächen jeglicher Bedeckung und Nutzung. Jedoch können, basierend auf einer weiteren Selektion, jene Baublöcke angesprochen werden, welche die hier bereits selektierten Wohngebäude umgeben. Diese zweite Selektion bietet die geometrische Basis zur Berechnung der Puffer. Nach der Umwandlung des Landbedeckungsrasters in Punktdaten können mittels einer einfachen Verschneidung sämtliche Punkte pro Puffer in Abhängigkeit ihrer jeweiligen Klasse ausgezählt werden. Da jeder Punkt einer Fläche von 100m² entspricht, kann im nächsten Schritt der Flächenanteil jeder Landbedeckungsklasse gegenüber der Fläche des jeweiligen Puffers berechnet werden. Über die räumliche Beziehung der Gebäude zu den Puffern ist es nunmehr möglich, diesen Flächenanteil den zum jeweiligen Baublock gehörenden Gebäuden zuzuweisen.

Um den Einfluss der Landbedeckung hinsichtlich der Genauigkeit der Klassifikation bewerten zu können, wurden zwei Klassifikationen durchgeführt, wobei ein Durchgang mit und ein Durchgang ohne die Information der Landbedeckung gerechnet wurde.

4.1.3. Berechnung weiterer Gebäudemerkmale

Um den verfügbaren Informationsgehalt mit Blick auf die Klassifikation zu erweitern, wurden auf Basis der Gebäudegrundrisse weitere Formparameter nach Wurm, Schmitt, und Taubenböck (2016) berechnet. Die hier kalkulierten **Formparameter** umfassen:

- Einfache geometrische Indizes (2D + 3D). Beispiele wären:
 - Fläche
 - Durchmesser
 - Volumen
- Indizes, welche die Gebäudeform in Relation zur Geometrie eines
 - idealen Kreises (2D),

- idealen Rechtecks (2D),
- Quadrates (2D) und eines
- Kubus (3D)

setzen

- Indizes, welche die Asymmetrie wiedergeben (2D + 3D)

Detaillierte Beschreibungen, sowie die den jeweiligen Indizes zugrundeliegenden Formeln können Wurm, Schmitt, und Taubenböck (2016) entnommen werden. Unter Zuhilfenahme dieses Satzes an Indizes können die einzelnen Gebäudeformen äußerst detailliert in 2D, wie auch in 3D, beschrieben werden. So wurde seitens der genannten Autoren bereits der Nutzen dieser Parameter zur Differenzierung verschiedener Gebäudetypen nachgewiesen.

Zusätzlich wurden Parameter hinsichtlich der jeweiligen Stockwerke berechnet. Da im Vorfeld keinerlei Angaben zu einer für Baden – Württemberg einheitlich anzunehmenden Stockwerkshöhe gegeben waren, wurde der empirisch errechnete Mittelwert nach Wurm et al. (2009) genutzt. Demnach wird der Wert von 3,35m einheitlich jedem Stockwerk zugewiesen. Eine tiefergehende Differenzierung in Abhängigkeit des jeweiligen Gebäudes war aufgrund fehlender Datengrundlage nicht möglich. Die entsprechenden stockwerksbezogenen Parameter, die hier berechnet wurden, sind:

- **Geschossanzahl**

Hierfür wurde die Höhe des Gebäudes in Relation zur Stockwerkshöhe gesetzt

- **Geschossfläche**

Diese berechnet sich als Produkt aus Geschossanzahl x Grundfläche

- **Geschossflächendichte**

Hierfür wird die Geschossfläche aller Gebäude innerhalb eines Baublocks (LBM-DE) in Relation zu dessen Fläche gesetzt

Um die Gebäudestruktur pro Baublock (LBM-DE) besser beschreiben zu können, wurde noch der Parameter der Bebauungsdichte berechnet. Dieser ergibt sich aus dem Quotienten von Gebäudeflächen des Baublocks zur Gesamtfläche des Baublocks.

Mittels räumlicher Verschneidung wurden die oben beschriebenen Parameter jedem Gebäude zugewiesen. Zusätzlich dazu wurden die bereits in Kapitel III beschriebenen Satelliten – Daten hinzugefügt, inklusive der Texturen.

Insgesamt ist demnach für jedes Gebäude Kontextinformation im Umfang von 78 Parametern verfügbar. Diese dienen im Folgenden als Input zur Klassifikation der Gebäudetypen.

4.2. Klassifikation der Gebäudetypen

4.2.1. Klassenschema und Sampling

Die hier zu differenzierenden Gebäudetypen entsprechen im Grundsatz denen von Loga et al. (2015). Jedoch konnten aufgrund des deutlich geringeren Umfanges an Eingangsdaten im Rahmen der vorliegenden Arbeit einige Klassenunterteilungen nicht berücksichtigt werden.

Tabelle 11: Klassenschema für Gebäudetypen; EFH = Einfamilienhaus, RH = Reihenhäuser, MFH = Mehrfamilienhaus, AB = Apartment - Block

Baualter	Größe			
	EFH	RH	MFH	AB
1859 - 1957	11	12	13	14
1958 - 1994	21	22	23	24
1995 - 2017	31	32	33	

Tabelle 11 zeigt das hier gewählte Klassenschema. Hierbei gilt: Gebäudetyp = [x][y], wobei x = Baualter und y = Größe. Demnach wird nach 4 Größenklassen und jeweils 3 Baualterklassen differenziert. Diese Unterteilung ist nicht zuletzt aufgrund der Tatsache wichtig, dass die folgende Ableitung der Wärmebedarfswerte ebenfalls auf Grundlage der Daten von Loga et al. (2015) vorgenommen wird. Insofern wurden hier die dazu notwendigen Parameter in das Klassifikationsschema übernommen. Dies erklärt auch die Unterteilung der Klasse 24, wobei die genannten Autoren hier ebenfalls keine Unterteilung vorgenommen haben. Dies ist dem Umstand geschuldet, dass für

eine tiefergehende Differenzierung zwischen den beiden jüngeren Altersklassen schlicht zu wenig Daten vorlagen.

Da im Rahmen dieser Arbeit weder Luftbilder, noch ein Höhenmodell mit einer sehr hohen Auflösung räumlichen verfügbar waren, wurde das Sampling mit Hilfe von GoogleEarth durchgeführt. Ein Sampling auf Basis der Sentinel-2 – Daten wäre hier mit Blick auf deren räumliche Auflösung nicht zielführend. Vielmehr wurde die 3D Information innerhalb von GoogleEarth, ebenso wie GoogleEarth – Streetview genutzt, um die in Tabelle 11 genannten Gebäudetypen zu differenzieren. Da die Information der dritten Dimension jedoch nur für einige wenige Städte, wie beispielsweise Stuttgart, Mannheim oder Karlsruhe verfügbar sind, war die Durchführung der visuellen Bildinterpretation auch nur in eben diesen Bereichen möglich. Dies birgt vor allem mit Blick auf den Umfang der erstellten Samples einen erheblichen Nachteil.

Tabelle 12: Sampling für Gebäudetypen

Klasse	Samples		
	Anzahl (Gesamt)	Anzahl (Training)	Anzahl (Validierung)
11	188	63	125
12	71	24	47
13	191	64	127
14	81	27	54
21	249	83	166
22	233	78	155
23	222	74	148
24	169	56	113
31	196	65	131
32	126	42	84
33	193	64	129

Tabelle 12 zeigt die Aufteilung der Samples auf die verschiedenen Gebäudeklassen. Hierbei fällt die teils stark unterschiedliche Gesamtzahl ins Auge. Die Ursache hierfür liegt darin begründet, dass die Erstellung der Samples rein auf Basis der visuellen Interpretation durchgeführt wurde. Entsprechend konnten nur solche Gebäude klassifiziert werden, welche eine mehr oder weniger eindeutige Zuordnung erlaubten. Die Unterscheidung zwischen den einzelnen Gebäudegrößen (EFH, RH, MFH und AB) wurde im Wesentlichen basierend auf der abzuschätzenden Anzahl der ersichtlichen Stockwerke vorgenommen und richtet sich nach den entsprechenden Kennwerten von Loga et al. (2015). Lediglich die Klasse der Reihenhäuser bildet hier eine Ausnahme. Basis einer Zuordnung eines Gebäudes zu dieser Klasse war das Vorhandensein mindestens einer Außenwand, welche direkt an ein Nachbargebäude anschließt.

Die Einschätzung des jeweiligen Baualters basiert im Wesentlichen auf der in GoogleEarth ersichtlichen Fassadenoptik, sowie der Lage eines Gebäudes im räumlichen Kontext der betrachteten Stadt. Mögliche bereits durchgeführte Sanierungsmaßnahmen an den jeweiligen Gebäuden konnten dementsprechend nicht berücksichtigt werden. Da die Erwartungen hinsichtlich Genauigkeit gegenüber der Differenzierung nach Gebäudegröße höher sind, als gegenüber der Baualtersklasse, wurden zwei Klassifikationsansätze verfolgt, wobei jeweils die Baualtersklasse Berücksichtigung, bzw. keine Berücksichtigung findet.

Die Samples wurden für die hier durchgeführte Klassifikation in zwei Datensätze mit je einem Drittel (Training), bzw. zwei Drittel (Validierung) der Gesamtanzahl geteilt. Wurden in GoogleEarth lediglich Punkte erstellt, welche die Lage der Gebäude wiedergeben, so erfolgte auf Basis derer die Selektion der jeweiligen LoD1 – Gebäudegrundrisse.

Als Klassifikator wurde der bereits in Kapitel 3.1.3 beschriebene Random Forest genutzt.

4.2.2. Ergebnisse der Klassifikation

Tabelle 13 bietet eine Übersicht über die verschiedenen Klassifikationsansätze, welche oben bereits beschrieben wurden. Analog zu Kapitel 3.1.5 werden zuerst die jeweiligen Genauigkeiten der verschiedenen Ansätze genauer betrachtet. Jener mit der besten Genauigkeit wird anschließend verwendet, um die Wärmebedarfswerte abzuleiten.

Tabelle 13: Übersicht über die Klassifikationsansätze

Klassifikationsansatz	Input		
	Aggregiert [j / n]	Landbedeckung [j / n]	Baualter [j / n]
1	n	n	j
2	j	n	j
3	j	j	j
4	j	j	n

Klassifikationsansatz 1

Die Gesamtgenauigkeit dieser Klassifikation beträgt rund 0,42. Der dazugehörige Kappa – Index weist mit 0,36 einen ähnlichen Wert auf.




Abbildung 32: TPR - Klassifikationsansatz 1

Abbildung 32 zeigt den Grad an Unterschätzung der Gebäudetypen. Dabei fällt Klasse 12 besonders ins Auge. Hier scheint eine massive Unterschätzung dieser Klasse vorzuliegen, was wiederum ein Hinweis auf eine zu geringe Anzahl der zugrundeliegenden Samples sein könnte (siehe Tabelle 12). Ebenso wurden die Klassen 14, 32 und 33 erheblich unterschätzt. Somit wird insbesondere der Gebäudetyp Reihenhaus in Abhängigkeit des Baualters unterschätzt. Lediglich Klasse 22 sticht hervor, wobei der Wert hier unter 50% liegt. Die Einfamilienhäuser (11,21,31) weisen eine demgegenüber deutlich geringere Rate an Unterschätzung auf, wobei hier die älteste Klasse (11) stark von den jüngeren Gebäuden abweicht. Im Falle der Mehrfamilienhäuser stellt sich die älteste Klasse (13) als am besten klassifiziert dar. Die neuesten Mehrfamilienhäuser (33) wurden im Vergleich dazu stark unterschätzt. Bei den Apartment – Blocks ist die altersbezogene Diskrepanz besonders hoch: während Klasse 24 die 60% - Marke übersteigt, erreicht Klasse 14 gerade einmal rund 26%. Betrachtet man lediglich die unterschiedlichen Baualtersklassen, weist die mittlere im Mittel die besten Ergebnisse hinsichtlich der Unterschätzung auf.




Abbildung 33: TNR - Klassifikationsansatz 1

Gegenüber der TPR zeigt Abbildung 33 einen deutlich homogenen Verlauf der TN – Rate über die Gebäudetypen. Hierbei scheint die mittlere Altersklasse im Vergleich am schlechtesten abzuschneiden, wobei dennoch der Wert von ca. 80% nicht unterschritten wird. Mit Blick auf die Altersklassen spiegelt die älteste Klasse im Mittel die geringste Rate an Überschätzung wieder. Hingegen weist die mittlere Altersklasse im Mittel die schlechteste auf, was im Gegensatz zu Abbildung 32 steht. Generell, über alle Klassen hinweg, werden die Einfamilienhäuser am häufigsten überschätzt. Demgegenüber scheinen größere Gebäude (13, 14, 23, 24 und 32) seltener überschätzt zu werden.

Mit Blick auf Tabelle 14 soll eine genaue Betrachtung der Fehlklassifikationen zwischen den einzelnen Klassen erfolgen. Im Fokus stehen hierbei einerseits Fehler zwischen den Altersklassen und andererseits Fehler zwischen den jeweiligen Gebäu-
degrößen. Generell lässt sich jedoch bereits bei erster Betrachtung feststellen, dass es eine Vielzahl an Fehlern zwischen sämtlichen Klassen gibt, wobei hier unbedingt

Tabelle 14: Konfusionsmatrix - Klassifikationsansatz 1

		Ref.										
		11	12	13	14	21	22	23	24	31	32	33
Klas- sif.	11	39	3	11	0	19	7	7	1	8	1	6
	12	3	5	0	0	6	3	1	0	0	0	1
	13	5	15	75	21	1	5	18	6	1	0	1
	14	0	2	4	14	0	0	2	5	0	0	0
	21	36	6	8	1	73	30	16	0	18	5	6
	22	14	8	2	0	14	75	5	0	17	30	12
	23	5	1	10	3	5	6	62	16	9	4	18
	24	0	2	14	13	0	2	15	70	1	3	23
	31	20	3	3	0	42	12	8	0	62	14	11
	32	0	0	0	0	0	13	0	1	7	25	8
	33	3	2	0	2	6	2	14	13	7	2	42

die Anzahl der verfügbaren Samples pro Klasse berücksichtigt werden muss. Mit Bezug auf Klasse 11 zeigt sich, dass es viele Fehlklassifikationen der Klassen 21 und 31 gegeben hat. Dies gilt besonders für unterschätzte Samples. Hier gibt es also erhebliche Schwierigkeiten, zwischen den Altersklassen zu differenzieren. Im Fall von Klasse 12 zeigt sich die Schwierigkeit der Differenzierung besonders: hier wurden 15 Samples der Klasse 13 zugewiesen, sowie 8 der Klasse 22. Hier scheint eine explizite Klassifikation kaum möglich. Diese These wird weiterhin aufgrund der Anzahl der überhaupt der Klasse 12 zugeordneten Samples deutlich. Zwischen den Klassen 22 und 32 gibt es ebenfalls erhebliche Probleme hinsichtlich einer Unterscheidung. Mit 30 Zuweisungen zu Klasse 32 wurde Klasse 22 massiv überschätzt. Bezüglich der Mehrfamilienhäuser besteht insbesondere ein Problem zwischen den Klassen 23 und 33. Generell kann also anhand der Tabelle 14 die Aussage formuliert werden, dass die Differenzierung zwischen Altersklassen deutlich mehr Fehler zur Folge hat, als die Differenzierung zwischen den Gebäudegrößen.

Klassifikationsansatz 2

Dieser Ansatz unterscheidet sich vom ersten darin, dass die Wohngebäude hier aggregiert wurden (siehe Kapitel 4.1.1). Dabei wurde eine Gesamtgenauigkeit von 0,4, sowie ein Kappa – Wert von 0,32 erreicht. Hierfür zeigt Abbildung 34 die TP – Raten der einzelnen Klassen. Wie bereits für Ansatz 1, fällt hier die Klasse 12 auf, wobei hier gerade ca. 2% erreicht werden. Somit wurde diese Klasse massiv unterschätzt. Ähnlich, jedoch weniger markant verhält es sich bei Klasse 32. Demgegenüber steht ein vergleichbar hoher Wert von ca. 53% der Klasse 22.




Abbildung 34: TPR - Klassifikationsansatz 2

Für die Mehrfamilienhäuser ist für alle Altersklassen ein vergleichbarer Wert von ca. 30% zu verzeichnen. Auch hier wurden die Klassen jeweils stark unterschätzt. Bezüglich der Größe können die Einfamilienhäuser hervorgehoben werden, welche im Schnitt den höchsten Wert aufweisen. Klasse 11 unterliegt hier mit rund 28% der größten Unterschätzung. Am wenigsten unterschätzt wurde Klasse 24 mit ca. 62%. Die analoge Größenklasse 14 weist einen erheblich niedrigeren Wert von ca. 30% auf.

Hinsichtlich der Überschätzung sind klare Parallelen zu Abbildung 34 zu erkennen. Der größten Überschätzung unterliegt Klasse 21, gefolgt von 22 und 23. Hier scheint die

Überschätzung innerhalb einer Altersklasse mit der Gebäudegröße zuzunehmen. Für die älteste, bzw. jüngste Altersklasse weisen die Reihenhäuser jeweils den höchsten Wert von ca. 0,9% auf. Die Ein- bzw. Mehrfamilienhäuser dieser Altersklassen werden jeweils um die gleiche Rate von ca. 80% überschätzt. Explizit für die Reihenhäuser ist an dieser Stelle die massive Unterschätzung, bei gleichzeitig nur minimaler Überschätzung zu vermerken. Der Vergleich zwischen Abbildung 34 und 35 zeigt aber generell einen weit homogenen Verlauf der TN – Rate für alle Klassen, im Vergleich zur TP – Rate. Entsprechend ist auch hier die Unterschätzung der jeweiligen Klassen das maßgebliche Problem des gewählten Klassifikationsansatzes.




Abbildung 35: TNR - Klassifikationsansatz 2

Tabelle 15 dient wiederum der klassenspezifischen Zuweisung der einzelnen Fehler. Zwischen Klasse 11 und 21 ist die eingeschränkte Differenzierbarkeit deutlich zu erkennen. Gleiches gilt für die Klassen 21 und 31. Ähnlich verhält es sich bei den Reihenhäusern: mit 27 Samplen wurde Klasse 22 zu Lasten von 32 deutlich überschätzt. Klasse 12 hingegen wurde generell nicht erkannt. Vielmehr wurde diese Klasse v.a. zugunsten von Klasse 22 sehr deutlich unterschätzt. Zwischen den verschiedenen Altersklassen der Mehrfamilienhäuser gibt es ebenfalls Schwierigkeiten. So wurde Klasse 23 mit 31 Samplen der Klasse 33 stark überschätzt. Gleiches gilt für Klasse 13.

Generell lässt sich mit Blick auf Tabelle 15 bemerken, dass die Einfamilienhäuser durchaus gut erkannt wurden, sofern man die Altersklasse nicht beachtet. Schwierigkeiten bezüglich der Größenklasse gibt es vor allem bei den größeren Gebäuden, d.h. zwischen MFH und AB.

Tabelle 15: Konfusionsmatrix - Klassifikationsansatz 2

		Ref.										
		11	12	13	14	21	22	23	24	31	32	33
Klas- sif.	11	35	2	8	0	33	4	4	0	13	0	2
	12	0	1	1	0	0	0	0	0	1	0	0
	13	2	9	45	18	0	6	16	7	0	0	3
	14	0	4	10	15	0	0	1	2	0	0	1
	21	67	1	14	0	92	14	19	0	36	6	6
	22	1	17	11	2	4	83	20	16	9	27	19
	23	3	6	21	1	4	18	55	12	4	7	31
	24	0	1	9	15	0	4	15	70	1	3	9
	31	15	2	3	0	29	4	1	0	55	5	15
	32	0	1	0	0	0	7	3	2	2	17	6
	33	1	2	2	0	4	14	13	2	9	21	36

Jedoch gilt auch für die Klasse 24 eine Überschätzung von immerhin 15 Samples der Klasse 14. In Anlehnung an den ersten Ansatz scheinen hier ebenfalls mehr Schwierigkeiten vorzuliegen zwischen den Altersklassen, als zwischen den Größenklasse zu differenzieren.

Klassifikationsansatz 3

Dieser Ansatz soll im Wesentlichen herausarbeiten, in wie weit das Integrieren der Information zur Landbedeckung die Klassifikationsgenauigkeit beeinflusst. Im Zuge dieser Klassifikation wurde eine Gesamtgenauigkeit von 0,40, sowie ein Kappa – Wert von 0,34 erreicht. Ausgehend von diesen beiden Werten ist keine Verbesserung hinsichtlich der Genauigkeit im Vergleich zu den vorherigen Ansätzen erkennbar. Gleiches gilt mit Blick auf Abbildung 36. Wie bereits zuvor weist Klasse 12 die mit Abstand geringste TP – Rate von ca. 5% auf. Auch Klasse 32 unterliegt weiterhin einer erheblichen Unterschätzung. Abgehoben stellen sich die Raten für die Klassen 24, 21 und 22 dar, wobei Klasse 24 mit rund 62% die vergleichsweise geringste Unterschätzung aufweist. Bezüglich der Altersklassen erzielt die mittlere die besten Werte. Lediglich

Klasse 31 mit ca. 46% liegt darüber. Die ältesten, sowie die jüngsten Reihenhäuser wurden nach Abbildung 36 deutlich unterschätzt. Demgegenüber steht Klasse 22 mit einem Wert von immerhin rund 57%. Die modernen Apartment – Blocks zeigen den höchsten Wert dieser Klassifikation, wobei Klasse 14 deutlich darunter liegt.

Über alle Klassen hinweg ist hier festzustellen, dass die mittlere Altersklasse die höchsten Werte der TPR aufweist. Hingegen obliegt die älteste Klasse der höchsten Rate an Unterschätzung.




Abbildung 36: TPR - Klassifikationsansatz 3

Mit Blick auf Abbildung 37 zeigt sich, analog zu den vorherig beschriebenen TN – Raten, ein im Vergleich zur TPR einheitlicher Verlauf der klassenspezifischen Werte. Dabei fällt die mittlere Altersklasse auf. Hier ist ein nahezu linearer Anstieg in Abhängigkeit der Gebäudegrößen zu verzeichnen, wobei Klasse 24 mit ca. 96% den höchsten Wert aufweist. Die Klassen 12 und 32 fallen durch ihre Werte nahe 100% auf, wohingegen beide Klassen einer erheblichen Unterschätzung unterliegen (s.o.). Im Falle der Reihenhäuser fällt Klasse 22 mit ca. 85% aus der Reihe. Gleiches gilt für Klasse 21.

Im Sinne der Auswertung, ob das Integrieren der Information zur Landbedeckung das Klassifikationsergebnis verändert, kann mit Blick auf die Abbildungen 36 und 37 nur eine Betrachtung der klassenspezifischen Fehler, sowie korrekten Zuordnungen

helfen. Bevor jedoch eine Analyse der entsprechenden Konfusionsmatrix erfolgt, wird hier eine weitere Komponente in Augenschein genommen. Dabei handelt es sich um den klassenspezifischen Flächenanteil einer Landbedeckungsklasse in Abhängigkeit der jeweiligen Distanz.




Abbildung 37: TNR - Klassifikationsansatz 3

Der Begriff der Distanz bezieht sich hier auf definierten Radius des erstellten Puffers (siehe dazu Kapitel 4.1.2). Im Rahmen dieser Arbeit wurde der Radius von 100m definiert, um eine erste Analyse dieses Parameters zu ermöglichen. Abbildung 38 stellt die verschiedenen Flächenanteile der jeweiligen Landbedeckungsklassen den Gebäudeklassen gegenüber. Diese Betrachtungsweise soll dazu dienen, markante Unterschiede bezüglich des Flächenanteils zwischen unterschiedlichen Gebäudetypen festzustellen.

Bereits im Vorfeld lässt sich feststellen, dass LC 40 keinerlei Differenzierung zwischen den Gebäudetypen zulässt. Lediglich einige wenige Ausreißer sind zu verzeichnen. Diese lassen sich auf verstreut vorkommende Seen zurückführen. Eine weitere Ursache für die dargestellte Streuung von LC 40 ist im Bereich des hier durchgeführten Samplings zu finden. So konnten, wie bereits besprochen, nur einige wenige Städte genutzt werden, um Referenzdaten zu generieren.

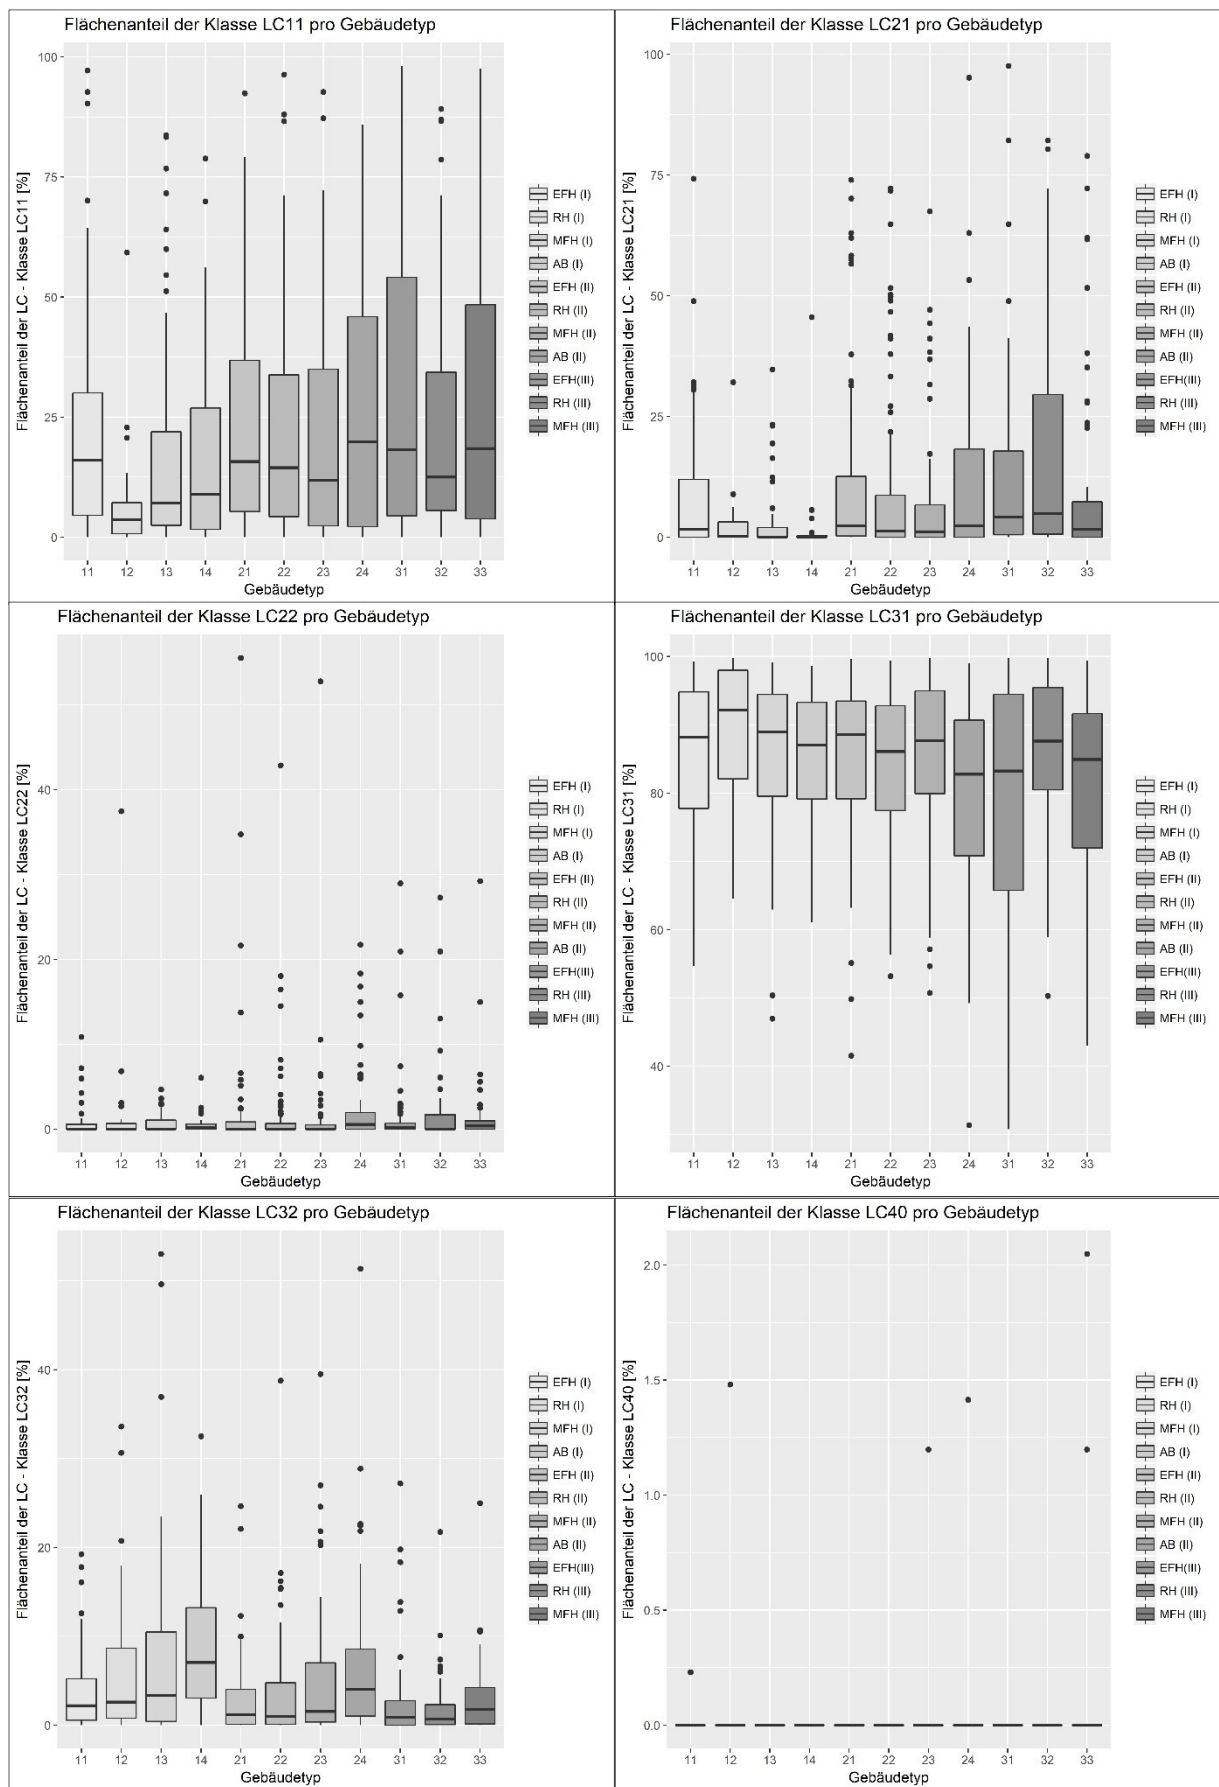


Abbildung 38: Flächenanteile der Landbedeckungsklassen pro Gebäudeklasse / Radius: 100m; LC = Landbedeckungsklasse

Die entsprechenden Referenzgebäude werden jedoch innerhalb eines 100m Radius von keiner größeren Wasserfläche umgeben. Für Klasse 22 zeigt sich ein ähnliches Bild, wobei hier rund 75% der Werte nahe 0 liegen. Jedoch gibt es deutlich mehr Ausreißer bis hin zu über 50%. Im Falle von Klasse 11 scheinen sämtliche Gebäudetypen in ihrer direkten Umgebung entsprechende Flächen aufzuweisen. Die größten Spannweiten mit ca. 45% haben die Gebäudeklassen 31 und 33. Dennoch liegt der Median in einem ähnlichen Bereich wie bei den übrigen Klassen. Dieselbe Vergleichbarkeit herrscht mit Blick auf den Interquartilsabstand. Generell wird ein Bild einer zunehmenden Spannweite mit gleichzeitig zunehmendem Gebäudealter gezeichnet. Gleichzeitig ist eine Unterscheidung auf Grundlage von LC11 wegen der über alle Gebäudeklassen hinweg markanten Überschneidungen der Flächenanteile kaum möglich. Was die Klasse 21 betrifft, so weisen die alten Apartment – Blocks den mit Abstand geringsten Flächenanteil auf. Auch die Reihenhäuser, sowie Mehrfamilienhäuser der ältesten Altersklasse scheinen nur wenige Acker- und Grünflächen in ihrer direkten Umgebung zu haben. Hinsichtlich der Spannweite ist ein ähnliches Bild wie bereits zuvor erkennbar, wobei die jüngeren Gebäude die größeren Spannweiten wiedergeben. Einzige Ausnahme bildet Klasse 33. Mit Ausnahme einiger Ausreißer sind jedoch auch hier große Überschneidungsbereiche über alle Gebäudeklassen hinweg gegeben, was eine Differenzierung auf Basis der LC21 erheblich erschwert. Eine Umkehrung der Verhältnisse zeigt sich mit Blick auf LC 31. Dies ist allerdings weniger überraschend, beachtet man die zugrundeliegende Bedeckungsklasse der Wohnflächen. Jedoch bleibt auch hier zu vermerken, dass die Spannweiten der Klassen 31 und 33 am größten sind. Weiterhin fallen die unteren 25% der Werte von Klasse 31 bis knapp über 30% Flächenanteil. Aber auch hier sind Überschneidungsbereiche über alle Gebäudeklassen deutlich zu erkennen. Mit Blick auf Industrieflächen (LC 32) fällt ein Merkmal besonders auf. So steigt einerseits der Flächenanteil der unteren 25% mit zunehmendem Alter an. Dies gilt insbesondere für die ersten beiden Altersklassen. Ebenso verhält es sich mit der Spannweite. Dies lässt den Schluss zu, dass vor allem Apartment – Blocks, aber auch Mehrfamilienhäuser tendenziell einen größeren Flächenanteil an Industrieflächen in direkter Umgebung haben. Hingegen stellt sich der Flächenanteil von Einfamilienhäusern, mit jeweils einem Median von unter 5%, sehr gering dar. Hier scheint also weniger die Altersklasse, als vielmehr die Gebäudegröße der entscheidende Faktor zu sein. Da aber auch hier erhebliche Anteile der Wertebereiche Überschneidungen aufweisen, ist eine Differenzierung nach Gebäudetyp auf Basis von

LC 32 nicht möglich. Fasst man diese Darstellungen zusammen, so lässt sich Folgendes festhalten:

- Die Überschneidungsbereiche der jeweiligen Flächenanteile sind zu groß als, dass eine Differenzierung der Gebäudetypen möglich wäre
- Es gibt durchaus einige Auffälligkeiten, die aber gleichzeitig eine eher schwache Ausprägung vorweisen. Diese Auffälligkeiten basieren sowohl auf dem Bezug der Altersklassen, wie auch der Gebäudegrößen zueinander.

Weiterhin muss hier berücksichtigt werden, dass lediglich ein Radius von 100m analysiert werden konnte. Im Falle der Landbedeckungsklassifikation entspricht dies 10 Pixel. Der Frage, ob eine markante Änderung der Landbedeckung auf solch einer Fläche wirklich zu erwarten ist, und wie man diesen Ansatz sinnvoll erweitern kann, wird im Kapitel der Diskussion nachgegangen.

Tabelle 16: Konfusionsmatrix - Klassifikationsansatz 3

		Ref.										
Klas- sif.		11	12	13	14	21	22	23	24	31	32	33
	11	39	1	8	0	35	3	4	0	11	0	1
	12	0	2	2	0	0	0	0	0	0	0	0
	13	2	8	45	18	0	4	14	5	0	0	4
	14	0	4	11	17	0	0	2	1	0	1	1
	21	66	3	13	0	94	15	20	0	38	6	7
	22	0	17	11	2	4	86	21	17	10	27	21
	23	3	4	19	0	4	12	53	13	3	6	28
	24	0	3	11	14	0	5	13	68	1	3	9
	31	13	1	3	0	25	5	3	0	60	7	14
	32	0	1	0	0	0	7	3	4	1	15	6
33	1	2	1	0	4	17	14	3	6	21	37	

Mit Verweis auf Tabelle 16 fällt im Vergleich zum vorhergehenden Klassifikationsansatz keine Veränderung im Sinne einer Verbesserung der Genauigkeit auf. Dies bedeutet, dass sich die Auffälligkeiten aus Abbildung 38 nicht auf die Klassifikation, bzw. auf deren Genauigkeit auswirken. Eine Ursache hierfür könnte u.a. sein, dass sich die genannten Auffälligkeiten tendenziell eher zwischen den Größenklassen, als zwischen den Altersklassen finden lassen. Um dieser Möglichkeit nachzugehen, differenziert der folgende Ansatz nunmehr nur noch zwischen den Größenklassen.

Klassifikationsansatz 4

Bereits mit Blick auf die Gesamtgenauigkeit von rund 0,67 fällt eine markante Verbesserung gegenüber den vorhergehenden Ansätzen auf. Gleiches gilt für den Kappa – Wert von ca. 0,55.




Abbildung 39: TPR und TNR - Klassifikationsansatz 4

Abbildung 39 gibt die TPR, bzw. die TNR für den vierten Ansatz wieder. Im Vergleich zu den ersten drei Ansätzen können hier deutliche Verbesserungen hinsichtlich Unter- und Überschätzung festgestellt werden. Insbesondere EFH erreichen nun einen Wert von rund 89% für TPR, sowie ca. 87% für TNR. Auch für die weiteren drei Größenklassen wurden deutliche Verbesserungen erreicht. Dies macht sich gerade bei der Klasse der Reihenhäuser bemerkbar. Hat die Klasse 12 in den vorherigen Ansätzen meist nur wenige % (TPR) aufgewiesen, so erreicht diese Klassifikation immerhin einen Wert von knapp über 50%. MFH und AB liegen hier ungefähr gleich auf, mit einer nur teilweisen Verbesserung gegenüber den vorherigen Ansätzen. Mit Bezug auf TNR ist feststellen, dass sich die Raten in ähnlichen Wertebereichen befinden, wie bei den oben beschriebenen Ansätzen. Im Fall der Klasse 02 wurde sogar eine Minderung des Wertes erreicht, was für eine leicht vorherrschende Überschätzung dieser Klasse spricht. Generell also gleichen sich die Unterschiede zwischen den Altersklassen aus, wenn man die Gebäudetypen lediglich nach Größenklasse differenziert. Vor allem die

erheblichen Unterschätzungsraten können somit, wenigstens teilweise, verringert werden.

Tabelle 17: Konfusionsmatrix - Klassifikationsansatz 4

		Ref.			
		EFH	RH	MFH	AB
Klassif.	EFH	378	34	71	0
	RH	12	154	61	26
	MFH	29	84	229	39
	AB	1	14	38	97

Für die Klasse der Reihenhäuser fällt auf, dass immer noch ein beträchtlicher Anteil der entsprechenden Referenzsamples anderen Klassen zufallen (Tabelle 17). So wer-




Abbildung 40: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene in Baden - Württemberg

den 84 Samples fälschlicherweise MFH zugerechnet, sowie 34 der Klasse EFH. Ein ähnliches Bild zeigt sich bei den anderen Klassen. Mit Abstand am besten schneiden die Einfamilienhäuser ab, wobei diese auch den größten Teil der Samples umfassen. Die Klassifikation der MFH ist für viele Samples problematisch. So wird diese gleichzeitig über- und unterschätzt, wobei sich die entsprechenden falschen Klassenzuweisungen auf sämtliche andere Klassen aufteilen.

Lediglich zwischen EFH und AB scheint es keine nennenswerten Schwierigkeiten zu geben. Für alle Klassen muss an dieser Stelle festgehalten werden, dass der größere Anteil der jeweiligen Samples einerseits richtig zugeordnet wurde, dass jedoch andererseits auch dieser Klassifikationsansatz keine optimale Differenzierung zwischen den Gebäudetypen zulässt.

Trotz dieser Einschränkung hinsichtlich der erzielten Genauigkeit lassen sich einige Aussagen zur Verteilung der Gebäudegrößen auf die Verwaltungsebenen treffen. Abbildung 40 zeigt hierzu beispielhaft die Anzahl pro Gebäudetyp auf Gemeindeebene. Entsprechende Abbildungen zu den weiteren Verwaltungsebenen finden sich im

Anhang (A2). Nach der hier gezeigten Abbildung stellen die Einfamilienhäuser die dominante Klasse dar. Demgegenüber stehen Apartment – Blocks.

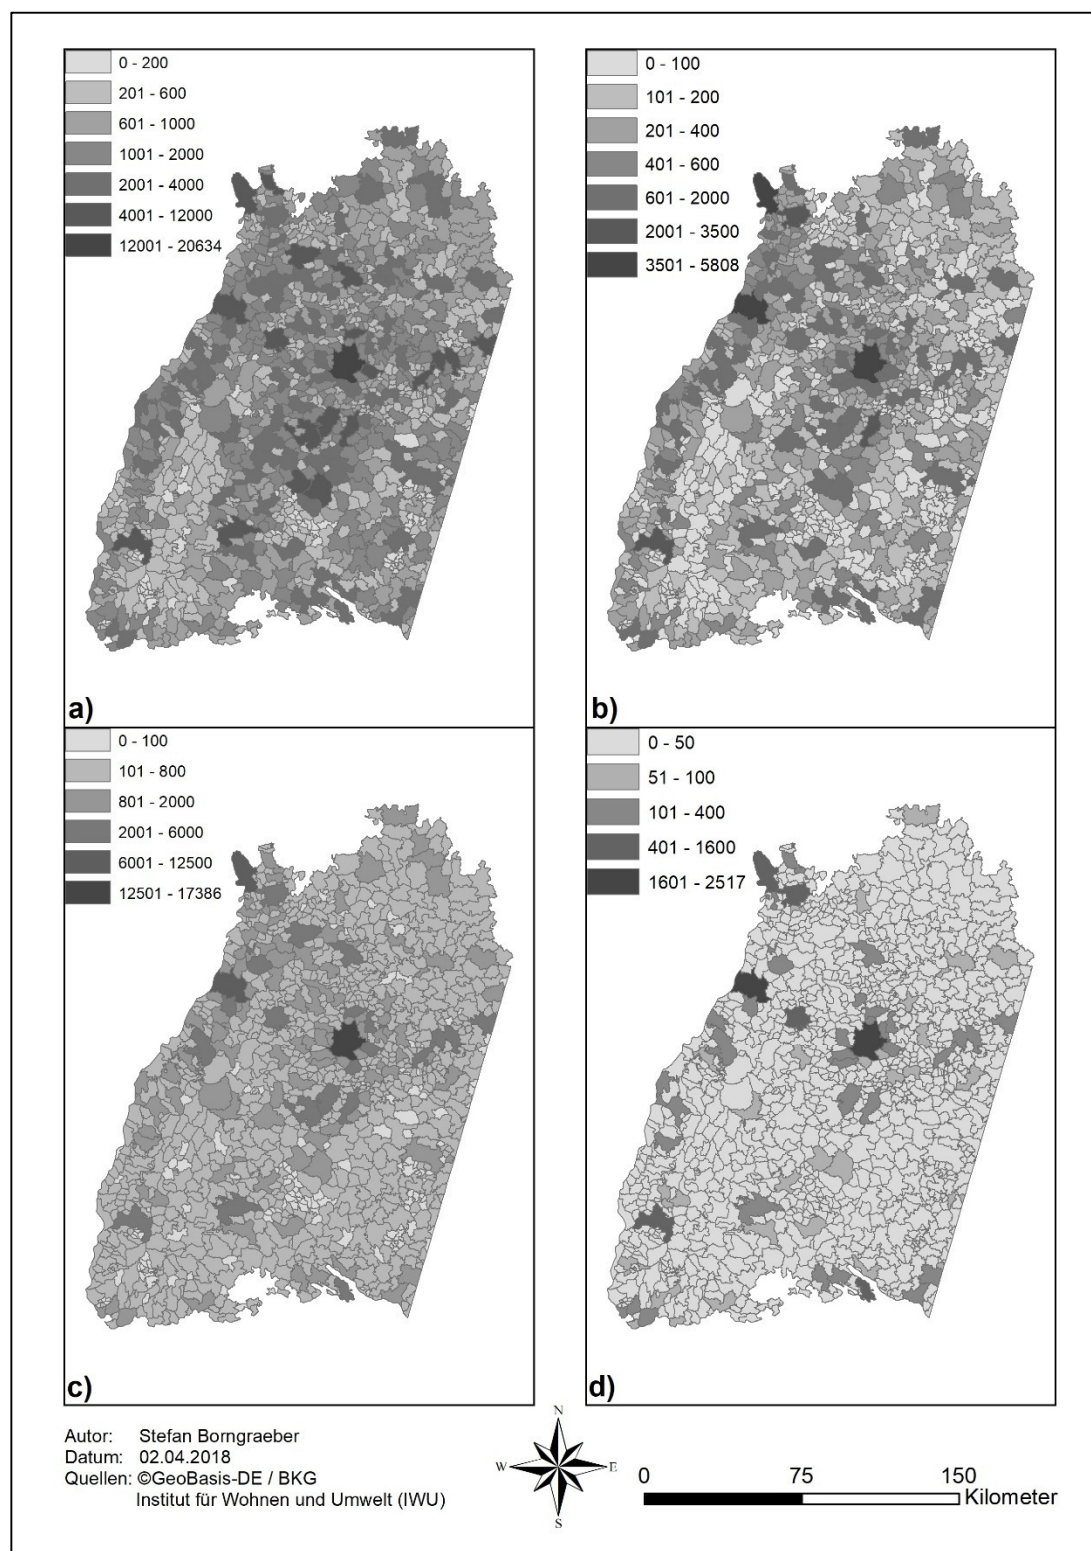


Abbildung 41: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene in Baden - Württemberg – Räumliche Verteilungsmuster; a) EFH, b) RH, c) MFH, d) AB

Hier spiegeln die Ausreißer Gemeinden in Bereichen größerer Städte, wie Karlsruhe oder Stuttgart wieder. Als Ergänzung liefert Abbildung 41 die räumlichen Verteilungsmuster der Gebäudetypen. Die statistische Streuung der Apartment – Blocks zeigt sich deutlich in Teilbild d). Hier sind vor allem die Gemeinden um Stuttgart, Freiburg, Karlsruhe, Mannheim und Friedrichshafen zu nennen. Die Gemeinden weisen auch im Falle der übrigen Gebäudetypen hohe Werte auf, wobei hier eine diversere Verteilung festzustellen ist. Während RH im Bereich der Schwarzwaldhochfläche kaum vorkommen, so sind dort EFH und MFH durchaus vertreten. Generell zeigt sich aber auch bei der räumlichen Darstellung das absolut häufigere Vorkommen der EFH gegenüber allen anderen Klassen.

Aufgrund der Tatsache, dass der Klassifikationsansatz 4 die besten Genauigkeiten liefert, werden die entsprechend klassifizierten Gebäudetypen im Folgenden dazu genutzt, die jeweiligen Wärmebedarfswerte abzuleiten.

4.3. Ableiten der Wärmebedarfswerte

Wie bereits oben angesprochen, gründet die hier vorgenommene Ableitung auf der Verknüpfung der erstellten Klassifikation nach Gebäudetypen und den dazugehörigen Wärmebedarfswerten nach Loga et al. (2015). Die in deren Arbeit vorgestellte Differenzierung stellt sich als weit tiefergehender dar, als die im Rahmen der vorliegenden Arbeit angewandte. Grund hierfür ist die verfügbare Datengrundlage, aufgrund derer eine weitergehende Differenzierung nicht möglich war. Um dennoch Bedarfswerte ableiten zu können, wurde ein Konzept entwickelt, welches auf Basis von Regeln zur Aggregation lediglich Bedarfswerte für die hier differenzierten Gebäudetypen ausgibt.

4.3.1. Konzept

Tabelle 18: Schema des Konzeptes zur Ableitung des Wärmebedarfs am Beispiel der EFH / Teil A; rote Linien entsprechen der Ober-, bzw. Untergrenze der hier gewählten Baualtersklasse

Klasse	Sub - Klasse (TABULA)	Mod - Paket	EFH - Netto [kWh / m²a]	Mittelwert (EFH - Netto [kWh / m²a])	Anzahl Geb pro AK (Subklasse)
1859 - 1957	...	IST	184	106,00	330000
		MP1	102		
		MP2	32		
	1860 - 1918	IST	181	109,33	966000
		MP1	105		
		MP2	42		
	1919 - 1948	IST	164	96,67	1131000
		MP1	92		
		MP2	34		
	1949 - 1957	IST	182	117,33	859000
		MP1	123		
		MP2	47		

Das hier entwickelte Konzept soll anhand von Tabelle 18 erläutert werden.

Grundlegend für die Zuteilung von Wärmebedarfswerten ist neben der Gebäudegröße vor allem das jeweilige Baualter eines Gebäudes. In Tabelle 18 zeigt die erste Spalte die im Rahmen dieser Arbeit genutzte, älteste Baualtersklasse (rot eingefärbt). Die zweite Spalte gibt demgegenüber die Differenzierung nach Loga et al. (2015), bzw. der von ihnen entwickelten Gebäudetypologie für Deutschland wieder. Wichtig hierbei ist die deutlich feinere Differenzierung der einzelnen Altersklassen. An die Altersklasse geknüpft sind nach Loga et al. (2015) sog. Modernisierungspakete (Spalte 3: Mod – Paket). Diese umschreiben den energetischen Zustand eines Gebäudes hinsichtlich der jeweiligen Effizienz. Gemeint sind vor allem bauliche Maßnahmen, wie beispielsweise Dämmung, Leitungssysteme oder auch Heizsysteme. Jeder Altersklasse wurden insgesamt drei Modernisierungspakete zugewiesen, wobei das erste dem IST – Zustand entspricht. Wie in der vierten Spalte anhand der Beispielwerte für EFH zu sehen, nimmt der Netto - Wärmeenergiebedarf mit zunehmender Modernisierung deutlich ab. Anzumerken bleibt hier, dass diese Abnahme keinesfalls linear verläuft. Aufgrund der Tatsache, dass es im Rahmen der vorliegenden Arbeit nicht möglich war, eine ähnlich feine zeitliche Differenzierung der Baualtersklassen auf Basis von GoogleEarth zu realisieren, wurden nun Regeln für eine Aggregation erstellt.

Im ersten Schritt wurde für Spalte 5 das arithmetische Mittel über die jeweiligen Modernisierungspakete errechnet. Dieses Schritt trägt der Tatsache Rechnung, dass keinerlei Informationen zum gebäudescharfen Sanierungszustand vorlagen. Über den Mittelwert erhalten dennoch alle Modernisierungsvarianten Einzug in die weiteren Berechnungen, wenn auch mit derselben Gewichtung. Verfügbar war jedoch die Anzahl der Gesamtgebäude pro Sub – Klasse, welche in Spalte 6 eingetragen ist.

Tabelle 19: Schema des Konzeptes zur Ableitung des Wärmebedarfs am Beispiel der EFH / Teil B; rote Linien entsprechen der Ober-, bzw. Untergrenze der hier gewählten Baualtersklasse

Summe (Anzahl pro Subklasse)	Gewichtung entspr. Anzahl Geb pro Subklasse	EFH - Netto gewichtet	EFH - Netto pro BAK [kWh / m²a]
3286000	0,10	10,65	106,73
	0,29	32,14	
	0,34	33,27	
	0,26	30,67	

Tabelle 19 zeigt die Fortsetzung von Tabelle 18. Die erste Spalte gibt die Summe der Gebäudeanzahl pro Subklasse wieder. Damit liegt ein Wert der Bestandsgebäude mit direktem Bezug zu der für diese Arbeit gewählten Baualtersklasse vor. Die Werte für die Anzahl der Bestandsgebäude wurden Diefenbach (2013) entnommen. Die Gewichtung in Spalte 2 generiert sich aus der Relation der Anzahl der Bestandsgebäude einer Subklasse zur Gesamtanzahl aller Gebäude pro Klasse. Diese Gewichtung wurde eingeführt, da die Netto – Bedarfswerte über die verschiedenen Subklassen teils deutlich variieren. Um dieser Variation Rechnung zu tragen, wurde der Anteil der Gebäude einer Subklasse am Gesamtbestand der Gebäude pro Klasse miteinbezogen. Der resultierende Faktor (Spalte 2) wird nun als Multiplikator für den bereits errechneten gemittelten Netto – Bedarf genutzt. Somit sind die Bedarfswerte in direkter Abhängigkeit zur Anzahl der zugrundeliegenden Gebäude im Bestand. Als Resultat erhält man den gewichteten Netto – Bedarf (Spalte 3). Um zuletzt den Bezug zur übergeordneten Klasse herzustellen, wurde mittels Summenfunktion erneut über die Subklassen aggregiert.

Insgesamt bestehen pro Klasse der Gebäudegröße drei Klassen, sowie 12 Subklassen. Als Ergebnis dieses schematisch vorgestellten Konzeptes erhält man also Wärmebedarfswerte [$\text{kWh} / \text{m}^2\text{a}$] für jede der drei Baualtersklassen. Diese können direkt mit den im vorherigen Kapitel klassifizierten Gebäudetypen verknüpft werden.

Für den Fall von Klassifikationsansatz 4 (Kapitel 4.3.1) wurde zudem eine weitere Aggregation mittels arithmetischem Mittel vorgenommen. Um einen diskreten Wert pro Gebäudegröße zu erhalten, wurde über alle drei Baualtersklassen gemittelt. Die vollständigen Tabellen, bzw. Zuweisungen des angewandten Konzeptes finden sich in Anhang – A3.

Tabelle 20: Wärmebedarfswerte pro Gebäudetyp

	Netto - Wärmebedarf [$\text{kWh} / \text{m}^2\text{a}$]			
Baualter	EFH	RH	MFH	AB
1859 - 1957	106,73	81,04	90,81	75,57
1958 - 1994	101,18	71,9	75,42	69,7
1995 - 2017	62,08	49,15	50,34	

Tabelle 20 zeigt die final errechneten Netto – Wärmebedarfswerte der hier genutzten Gebäudetypen. Für den Klassifikationsansatz 4 lauten die Werte entsprechend wie folgt:

- **EFH:** 90 kWh / m²a
- **RH:** 67,36 kWh / m²a
- **MFH:** 72,19 kWh / m²a
- **AB:** 72,63 kWh / m²a

Aufgrund der Anwendung des arithmetischen Mittels wurden die Bedarfswerte teils deutlich verringert. Dies sollte mit Blick auf die im Folgenden beschriebenen Ergebnisse beachtet werden.

4.3.2. Ergebnisse

Beispielhaft für die niedrigste Aggregationsebene zeigt Abbildung 42 die Wärmebedarfswerte für Wohngebäude am Beispiel Tübingen. Die zugrundeliegende Klassifikation entspricht dem vierten Ansatz. Betrachtet man zu allererst den Wertebereich, so fällt auf, dass die Werte lediglich zwischen 67 und 90 kWh / m²a schwanken. Diese nur geringen Unterschiede sind auf das im Vorfeld beschriebene Konzept zurückzuführen. Weiterhin ist zu konstatieren, dass unterschiedliche Siedlungsbereiche von einem Gebäudetyp dominiert werden. Gerade die Einfamilienhäuser wurden meist zusammenhängend klassifiziert, wobei hier entsprechend dem obigen Ansatz die höchsten Wärmebedarfswerte anzutreffen sind (rot eingefärbt). In Bereichen der Innenstadt mit dem Neckarkanal als südliche Begrenzung wurden meist Reihen-, sowie Mehrfamilienhäuser klassifiziert. Hier liegt entsprechend ein sehr niedriger Wärmebedarf vor. Ebenso wurde der Großteil der im zentralen Norden der Stadt gelegenen Wohnanlagen und Wohnheime korrekt klassifiziert (AB). Gedanklich nochmals daran erinnernd, dass die Wohngebäude mittels der klassifizierten Landbedeckung (Wohnflächen) selektiert wurden, fallen teilweise Lücken innerhalb von Wohngebieten ins Auge, welche nicht durch Gebäudepolygone abgedeckt sind. Der Grund hierfür ist die zu fein strukturierte Gliederung zwischen Siedlungsfläche und Grünland, welche basierend auf einer Auflösung von 10m nicht zu trennen ist. Dasselbe gilt für einen abrupten Wechsel zwischen Wohn- und Industrieflächen. Betrachtet man das Ergebnis jedoch mit Blick auf die gesamte städtische Fläche, kann eine ausreichende Grundgesamtheit gefunden werden, um statistisch valide Aussagen hinsichtlich des Wärmebedarfs treffen zu können.

Aggregiert man die gebäudescharfen Wärmebedarfswerte, so gelangt man zu Abbildung 43, wobei hier die mittleren Wärmebedarfswerte pro Verwaltungseinheit darge-

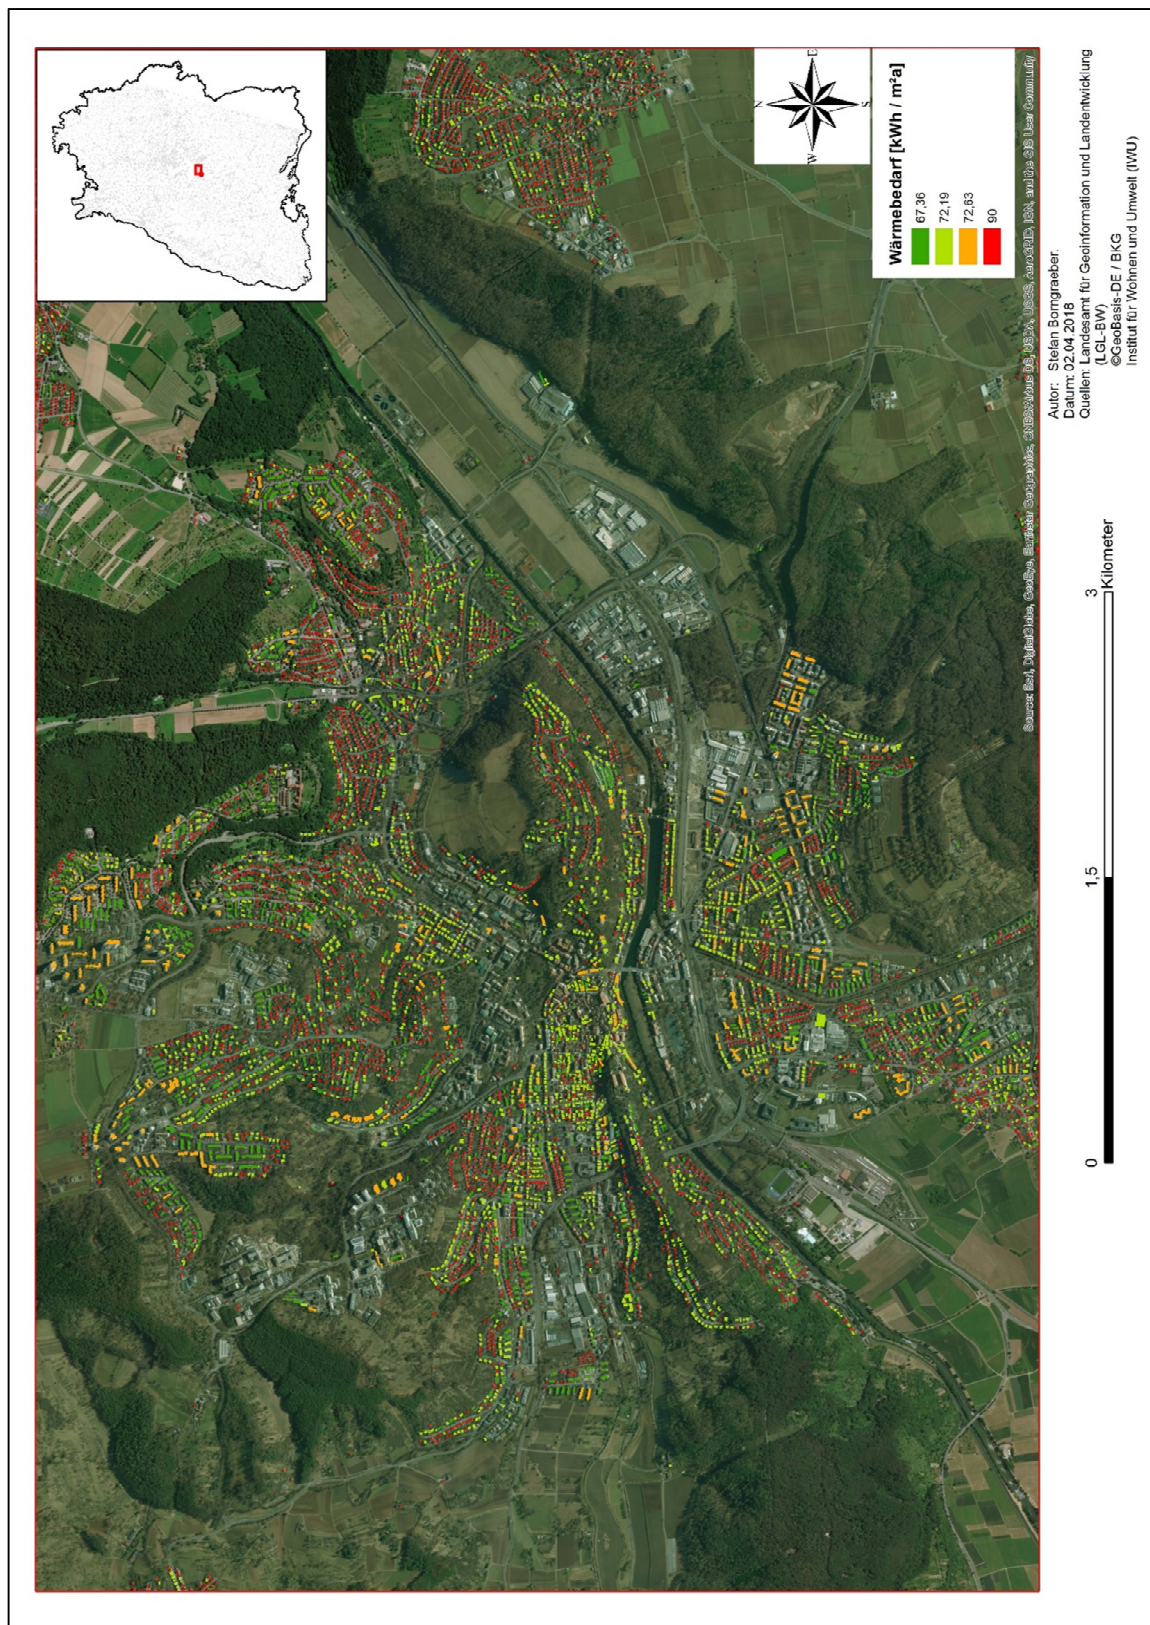


Abbildung 42: Wärmebedarfswerte auf Gebäudeebene am Beispiel Tübingen. Ergebnisse des vierten Klassifikationsansatzes

stellt wurden. Auf Gemeindeebene stellen sich die eng besiedelten Gebiete der größeren Städte als diejenigen dar, welche den geringsten Bedarf aufweisen. Jene

Regionen, die im ländlichen Gebiet, beispielsweise im Bereich der Schwäbischen Alb, oder auch südlich des Odenwaldes gelegen sind, weisen einen etwas höheren Bedarf auf. Mit Blick auf die Landkreise stechen ebenso die Gebiete rund um Freiburg, Stuttgart, Karlsruhe und Mannheim mit einem sehr niedrigen Bedarfswert hervor. Hingegen zeichnet sich ein Gürtel rund um Stuttgart ab, welcher die höchsten Bedarfswerte umfasst. Dies könnte mit Verweis auf die hier durchgeführte Klassifikation der Gebäudegrößen den Rückschluss nahelegen, dass in den entsprechend ländlichen Gebieten vornehmlich Einfamilienhäuser klassifiziert wurden. Da diese den höchsten Bedarfswert zugewiesen bekommen haben, sind Gemeinden und Landkreise mit überwiegender Bebauung dieser Gebäudegröße in jenen Bereichen mit den höchsten Bedarfswerten wiederzufinden. Hier kann eine Analogie zu der im Vorfeld erstellten Landbedeckungsklassifikation hergestellt werden, wonach der Regierungsbezirk Tübingen den geringsten Flächenanteil an Wohn-, bzw. Industrieflächen aufweist. Die entsprechend dominierende Klassifikation von Einfamilienhäusern kann hier auf den eher ländlichen Charakter zurückgeführt werden, was wiederum die hohen Wärmebedarfswerte nach sich zieht. Demgegenüber ist Karlsruhe derjenige Regierungsbezirk mit dem höchsten Flächenanteil an Industrieflächen. Da diese jedoch nicht in die Berechnung mit einbezogen wurden, fallen hier vor allem große städtische Wohngebäude auf, welche einen deutlich geringeren Verbrauchswert aufweisen als Einfamilienhäuser.

Jedoch muss auch hier unbedingt beachtet werden, dass die angesetzten absoluten Werte deutlich von den Werten abweichen, welche von Loga et al. (2015) den einzelnen Gebäudetypen zugewiesen wurden (siehe dazu Tabelle 20). Dies ist, wie bereits erwähnt, bedingt durch die hier notwendige Aggregation dieser Werte mittels des arithmetischen Mittelwertes. Da eine nicht – lineare Abnahme der Bedarfswerte mit zunehmender Modernisierung eintritt, fallen bei der Mittelung vor allem die deutlich geringeren Bedarfswerte der modernen Gebäude ins Gewicht, wobei die hohen Werte der Altbauten im Bestand nur noch marginal in der Statistik enthalten sind. Ebenso müssen die relativen Bezüge mit Vorsicht betrachtet werden, da im Rahmen des hier gezeigten vierten Klassifikationsansatzes lediglich die Gebäudegrößen klassifiziert wurden.

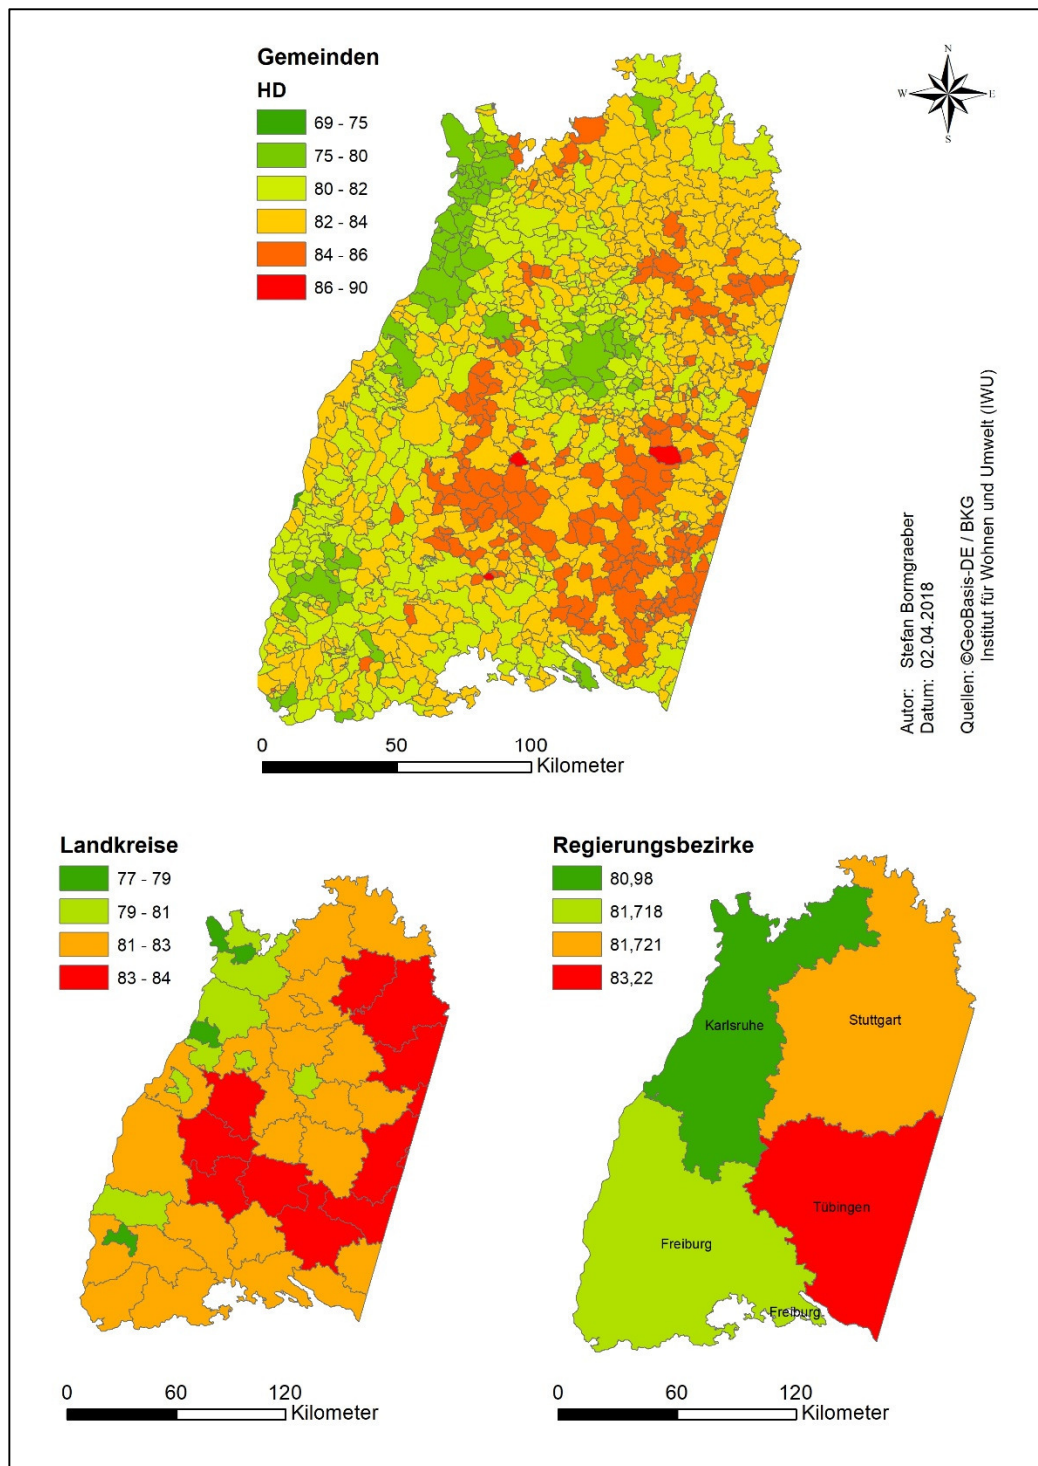


Abbildung 43: Mittlerer Wärmebedarf pro Verwaltungseinheit

Die in den Abbildungen 42 und 43 gezeigten Werte lassen also lediglich Rückschlüsse auf die zugrundeliegenden Gebäudegrößen zu, nicht aber auf das jeweilige Baualter. Gerade aus diesem Grund kann jedoch auf die bauliche Struktur zurückgeschlossen werden. Mit dem Fokus darauf sind die Klassifikationen in Abbildung 43, wie auch in Abbildung 42 durchaus nachvollziehbar. So ist davon auszugehen, dass gerade die

großen Apartment – Blocks vor allem in den städtische Bereichen zu finden sind. Diese Aussage wird u.a. durch Abbildung 40 gestützt.

An dieser Stelle kann keine Genauigkeitsabschätzung dieser Klassifikation durchgeführt werden, da die hierfür notwendigen Referenzdaten nicht zur Verfügung standen.

5. Zusammenfassende Betrachtung

Das hier vorgestellte Konzept zur Ableitung von Wärmebedarfswerten von Wohngebäuden in Baden – Württemberg umfasst im Wesentlichen zwei Schritte:

Zum einen die Klassifikation der Landbedeckung, basierend auf Sentinel-2 – Daten. Hier wurden sechs verschiedene Klassen klassifiziert: Wald, Äcker / Wiesen, Brachliegendes Ackerland, Wohnflächen, Industrieflächen und Wasserflächen. Da zusätzlich zu den Satellitendaten noch weitere Datensätze verfügbar waren, wurde die Klassifikation der Landbedeckung in zwei Phasen unterteilt: im Rahmen der ersten Phase wurde das Gebiet um die Stadt Heilbronn als Testgebiet festgelegt. Auf Basis dessen wurden verschiedene Varianten an Input – Datensätzen klassifiziert und die anschließenden Ergebnisse hinsichtlich der jeweils erreichten Genauigkeit verglichen. Jene Daten, welche auf visueller Bildinterpretation erstellt wurden, ergaben die höchsten Genauigkeiten und wurden folgerichtig zur Klassifikation der Gesamtszene für Baden – Württemberg genutzt. Die hierbei wiederum erzielten Genauigkeiten stellen sich als überaus gut dar, mit einer Gesamtgenauigkeit von rund 99%. Somit konnten die sechs Zielklassen nahezu optimal differenziert und klassifiziert werden.

Der zweite Schritt umfasst die Einbindung der erstellten Landbedeckungsklassifikation mit dem Ziel, Wärmebedarfswerte für Wohngebäude abzuleiten. Dies geschah auf zwei Wegen:

1. Die hier genutzten LoD1 – Gebäudegrundflächen wurden auf Basis der zuvor klassifizierten Wohnflächen selektiert. Diese Selektion wurde für die weiteren Schritte verwendet.
2. Auf Basis von Baublöcken (LBM-DE) wurden in Abhängigkeit eines definierten Puffers rund um die Blöcke die jeweiligen Flächenanteile der Landbedeckungsklassen berechnet. Diese gehen als Input – Daten mit in die Klassifikation der Gebäudetypen mit ein.

Zur Bestimmung der Wärmebedarfswerte waren zwei Schritte notwendig: einerseits wurden die Wohngebäude auf Basis einer Gebäudetypologie unterschieden. Hierbei wurde die bereits bestehende Typologie nach Loga et al. (2015) genutzt, welche Beispielgebäude für ganz Deutschland beschreibt. Diese Beschreibung umfasst bauliche Aspekte, welche die Variation des Wärmebedarfs eines Gebäudes bestimmen. Im Wesentlichen wird dabei zwischen Gebäudegröße und -alter differenziert. Dementsprechend wurde in Anlehnung daran eine für diese Arbeit angepasste Gebäudetypologie erstellt. Aufgrund der Tatsache, dass die bestehende Typologie eine weit tiefergehende Differenzierung beschreibt, als im Rahmen der vorliegenden Arbeit möglich war, wurde mittels statistischer Aggregierung die genannte Anpassung realisiert. Auch hier wurden verschiedene Klassifikationsansätze in Abhängigkeit der jeweils genutzten Input – Daten verglichen, um eine möglichst hohe Genauigkeit zu erzielen. Ergebnis dieser Vorab – Analyse war, dass weder die räumliche Aggregierung von Gebäuden, noch die Einbeziehung der Flächenanteile pro Landbedeckungsklasse eine Veränderung der Genauigkeit zur Folge hatten. Jedoch konnte eine markante Steigerung derselben erreicht werden, indem die Gebäudetypen lediglich basierend auf ihrer Größe, nicht aber dem Baualter klassifiziert wurden. Die Ergebnisse dieses letzten Ansatzes wurden dementsprechend genutzt, um das ebenfalls hier entwickelte Konzept zur Ableitung der Wärmebedarfswerte auf die Gebäudeklassen anzuwenden. Dieses Konzept beschreibt im Wesentlichen die Art und Weise, wie eine statistische Aggregierung der vorhandenen Gebäudetypologie aussehen kann, um die Werte an die hier vorliegenden Daten anzupassen. Diese Anpassung führte jedoch mit Blick auf die erhaltenen Ergebnisse dazu, dass die absoluten Wertebereiche des Wärmebedarfs pro Gebäudetyp drastisch reduziert wurden. Somit kann auf Basis der hier erstellten Klassifikation lediglich eine Bewertung der relativen Bezüge räumlicher Verteilungsmuster zueinander durchgeführt werden. Eine quantitative Analyse basierend auf den absoluten Werten wäre hier nicht zielführend. Zudem fehlen Daten für eine Genauigkeitsabschätzung.

Eine die gesamte Arbeit umgreifende Zusammenfassung der Ergebnisse, könnte wie folgt lauten: Die Klassifikation der Landbedeckung mit den hier genutzten Eingangsdaten funktioniert äußerst gut. Diese Feststellung muss aber unbedingt in Relation zu den hier vorherrschenden, bzw. definierten Rahmenbedingungen

gesetzt werden. Die direkte Einbindung der Landbedeckung als Eingangsdatensatz zur Klassifikation des Wärmebedarfs hat keinen messbaren Effekt auf die erzielte Genauigkeit. Die klassifizierten Werte des Wärmebedarfs können basierend auf der vorliegenden Anwendung des Konzeptes lediglich qualitativ analysiert werden. Die vorgenommene Aggregation verhindert eine quantitative Einschätzung. Zudem musste auf eine Genauigkeitsabschätzung der Werte verzichtet werden, da hierfür keine Referenzdaten vorlagen.

6. Diskussion und Ausblick

Mit Verweis auf die Struktur dieser Arbeit erfolgt die Diskussion der Arbeitsschritte in zwei Teilen: zuerst werden die einzelnen Schritte getrennt betrachtet und diskutiert. Im Anschluss erfolgt die Diskussion über die Verknüpfung der beiden hier durchgeführten Arbeitsschritte.

Mit Blick auf die Genauigkeit der hier erstellten Landbedeckungsklassifikation kann bereits vorab konstatiert werden, dass sich die Anwendung der Sentinel-2 Sensoren im Zusammenspiel mit den hier definierten Rahmenbedingungen sehr gut eignet. Nun sind es aber gerade diese Rahmenbedingungen, die eine Diskussion notwendig machen. Es muss, wie bereits oben kurz angedeutet, die Genauigkeit unbedingt im Verhältnis zu dem hier angewandten Klassifikationsschema, sowie generell zu den Randbedingungen gesehen werden. So kann an erster Stelle das Klassenschema betrachtet werden. Dieses zielt darauf ab, lediglich sechs Klassen der Landbedeckung zu unterscheiden. War dies für den hier vorliegenden Zweck ausreichend, so ist ebenfalls zu vermerken, dass dieser Umstand die Genauigkeit erheblich verbessert. Es wäre ebenfalls möglich, weitere Klassen, wie beispielsweise Laub- und Nadelwald, Straßen, oder auch innerstädtisches Grünland zu differenzieren. Eine solche tiefergehende Differenzierung der Landbedeckung würde ggf. eine Änderung der Randbedingungen erfordern, wobei dazu diverse statistische Analysen durchgeführt werden müssten. Als nächster Punkt muss das Sampling – Verfahren angesprochen werden. Das Ergebnis hinsichtlich der Genauigkeit steht in direkter Abhängigkeit zu diesem. So beziehen sich die Aussagen über beispielsweise die Überschätzung einer Klasse lediglich auf die Analyse jener Samples, welche im Rahmen der Validierung genutzt wurden. Zudem wurden die Samples in ihrer Gesamtheit auf Basis visueller Bildinterpretation generiert, was wiederum teils stark von individueller Einschätzung des Bearbeiters geprägt sein

kann. All diese Teilaspekte zusammengekommen führen zu einer gewissen Relativierung der hohen Genauigkeit.

Eine weit diversere Diskussion ist notwendig, befasst man sich mit dem zweiten Teil dieser Arbeit. So muss gleich zu Beginn festgehalten werden, dass hierbei das ausgewiesene Ziel die Entwicklung eines Konzeptes war, welches die Datensätze verknüpfend zu einer finalen Klassifikation der Wärmebedarfswerte von Wohngebäuden in Baden – Württemberg führt. Dementsprechend wurde dieses Konzept so entwickelt, dass es auch für weitere Studien nutzbar ist, da problemlos die Eingangsdaten getauscht und Zwischenschritte überarbeitet, oder ersetzt werden können. In erster Linie steht hier nun die Einbindung der Landbedeckung. Die Selektion der Wohngebäude auf Basis dieser Klassifikation erscheint durchaus sinnvoll, da so konsistent von einer Landbedeckung, nicht aber von Landnutzung gesprochen werden kann. Würden die Nutzungsinformationen der Lod1 – Daten genutzt, so würde diese Konsistenz verloren gehen. Abseits dieses thematischen Aspektes gilt es jedoch zu bedenken, welche räumlichen Auflösungsvermögen hier zugrunde liegen. So fasst jedes Pixel der Landbedeckungsklassifikation eine Fläche von 100m^2 . Eine gebäudescharfe Abgrenzung der Landbedeckung ist dementsprechend nicht möglich. Hingegen weisen die LoD1 – Gebäudegrundrisse eine erheblich feinere Auflösung, von rund $0,5\text{m}$, auf. Somit ist hier eine weitaus feinere Differenzierung gegeben. Bei einer räumlichen Verschneidung (Selektion) beider Datensätze kann dementsprechend keine absolute Deckungsgleichheit angenommen werden. So wurden oftmals, wie auch in den Abbildungen zu sehen, Grünbereiche innerhalb einer Siedlung zur Wohnfläche hinzugerechnet. Kleinere Gebäude in genau diesen Bereichen wurden also fälschlicherweise als Wohngebäude deklariert. Der angesetzte Flächenschwellwert von 50m^2 war hier ein Versuch, diesem Umstand beizukommen. Dennoch ist hier mit diversen Fehlklassifikationen zu rechnen. Die Berechnung der Flächenanteile einer Landbedeckungsklasse innerhalb eines definierten Radius um die Baublöcke weist ebenfalls diverse Schwächen auf. So wurde hier lediglich ein Radius (100m) angesetzt. Nun ist fraglich, ob innerhalb eines solch geringen Radius umfassende Änderungen hinsichtlich der Landbedeckung zu erwarten sind. Eine mögliche Erweiterung wäre es hier, deutlich mehr Radien, beispielsweise basierend auf einem 500m – Intervall heranzuziehen und die jeweiligen Flächenanteile der Landbedeckung zu berechnen. Liefern die Ergebnisse für sich genommen bereits einen Mehrwert, so können diese distanzabhängigen Flächenanteile

weiterhin zueinander in Bezug gesetzt werden. Beispielsweise könnte das Ergebnis einer angelegten räumlichen Regression über die Distanzen sein, dass in Abhängigkeit des Baualters der Flächenanteil der Landbedeckung Acker mit zunehmender Distanz abnimmt. Das hierbei resultierende Gleichungssystem könnte im Sinne der Klassifikation genutzt werden, um auf Basis des über die Distanz variierenden Flächenanteils das Baualter abzuleiten. Ebenfalls wäre die Stärke dieses Zusammenhangs in Form des Signifikanzniveaus gegeben, was wiederum eine anschließende detaillierte Analyse ermöglicht. Da solche Berechnungen, man bedenke den Bezugsraum eines Bundeslandes, äußerst rechenintensiv sind und einen hohen Zeitaufwand erfordern, musste im Rahmen der vorliegenden Arbeit darauf verzichtet werden.

Ein weiterer, überaus wesentlicher Punkt ist das hier entwickelte Konzept zur Ableitung der Wärmebedarfswerte. Die maßgebliche Einschränkung hierbei war der massive Mangel an eigentlich notwendigen Daten. Dieser Mangel begründet den Umstand, dass ein hoher Grad an Aggregation notwendig war, um die vorhandene Gebäudetypologie an die hier verfügbaren Daten anzupassen. So waren beispielsweise im Bereich der Höheninformationen lediglich jene verfügbar, welche im LoD1 – Datensatz gegeben sind. Wie bereits dargestellt, geben diese aber lediglich eine generalisierte Dachform, d.h. ein Flachdach wieder. Datensätze mit höherer Detailstufe wären hier durchaus sinnvoll, da diese darüber hinaus Informationen zu unterschiedlichen Dachformen pro Gebäude beinhalten. Diese Information könnte im Zuge der Klassifikation der Gebäudetypen zu Trainingszwecken genutzt werden, um das bestehende Klassifikationsmodell zu verbessern. Ebenfalls interessant wäre es, die hier verfügbaren Daten mit drei – dimensional Gebäudemodellen, wie beispielsweise das von Eicker et al. (2012) und Nouvel et al. (2013) beschriebene, zu verknüpfen, um statistisch basierte Zuordnungsregeln zu definieren. Diese könnten dann wiederum auf die hier verfügbaren Datensätze angewandt werden, um weitere für den Wärmebedarf relevante Parameter abzuleiten. Nicht zuletzt begründet der hier vorherrschende Datenmangel Art und Weise der Erhebung von Sample – Daten. Die angewandte Methodik der Bildinterpretation auf Basis von GoogleEarth ist sehr stark geprägt von individueller Sensibilität, bzw. Einschätzung der einzelnen Fassaden. So kann im Falle der hier erstellten Daten keinesfalls von einer absoluten Referenz gesprochen werden. Vielmehr handelt es sich um einen ersten Testdatensatz, um die Entwicklung des Konzeptes zu ermöglichen.

Alles in allem kann jedoch, trotz der beschriebenen Einschränkungen, von einem durchaus gelungenen Versuch gesprochen werden, ein Konzept mit dem genannten Ziel zu entwickeln. Dies zeigen nicht nur die Abbildungen der klassifizierten Wärmebedarfswerte, sondern ebenfalls die Klassifikation der Gebäudetypen. Zwar sind die absoluten Werte des Wärmebedarfs durchaus zu hinterfragen, doch werden dennoch markante siedlungsstrukturelle Aspekte wiedergegeben. Um die Möglichkeit der quantitativen Analyse der klassifizierten Bedarfswerte zu ermöglichen, benötigt es jedoch die Zuhilfenahme weiterer Datensätze, ebenso die weiterer Analysen.

Der Mehrwert des hier vorgestellten Konzeptes auf einer statistisch validen Basis ist durchaus weitreichend. So können auf Basis der Landbedeckung verschiedene Szenarien erstellt werden, um die lokale Versorgung über ökonomisch und ökologisch nachhaltige Versorgungssysteme zu gewährleisten. Weiterhin wäre eine landesweite, gebäudescharfe Informationsquelle des Wärmebedarfs von Wohngebäuden gegeben. In Kombination mit weiteren Informationen, beispielsweise Netzplänen, kann die optimale Anbindung von Gebäuden herausgearbeitet werden. Weiterhin ist es, wie in der Arbeit auch gezeigt, möglich, die Gebäudedaten auf verschiedene räumliche Ebenen zu aggregieren und so für Verwaltungseinheiten, wie beispielsweise Gemeinden, direkt verfügbare Informationen zu deren Wärmebedarf, sowie dessen räumliche Verteilung innerhalb und außerhalb der Gemeinde bereitzustellen. Diese Information wäre, basierend auf dem vorliegenden Konzept, nicht nur flächendeckend, sondern ebenfalls mit hoher zeitlicher Auflösung verfügbar.

7. Literaturverzeichnis

- Altman, D. G., und J. M. Bland. 1994a. "Diagnostic tests. 1: Sensitivity and specificity." *BMJ : British Medical Journal* 308 (6943): 1552.
- Altman, Douglas G., und J. Martin Bland. 1994b. "Statistics Notes: Diagnostic tests 2: predictive values." *BMJ* 309 (6947): 102.
- Bechtel, B. 2015. "Die Hitze in der Stadt verstehen – Wie sich die jahreszeitliche Temperaturdynamik von Städten aus dem All beobachten lässt." In *Globale Urbanisierung: Perspektive aus dem All*, H. Taubenböck, M. Wurm, T. Esch und S. Dech (Hrsg.), 205-16. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Bechtel, B. , K. Zakšek, und G. Hoshyaripour. 2012. "Downscaling Land Surface Temperature in an Urban Area: A Case Study for Hamburg, Germany." *Remote Sensing* 4 (10): 3184 - 200.
- Belgiu, Mariana, und Lucian Drăguț. 2016. "Random forest in remote sensing: A review of applications and future directions." *ISPRS Journal of Photogrammetry and Remote Sensing* 114: 24-31. doi: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BKG. 2018. "Digitales Landbedeckungsmodell für Deutschland - LBM-DE2015." 48. Bundesamt für Kartographie und Geodäsie.
- Blesl, M, S Kempe, M Ohl, U Fahl, A. König, T. Jenssen, und L. Eltrop. 2009. "Wärmeatlas Baden-Württemberg - Erstellung eines Leitfadens und Umsetzung für Modellregionen. ." 165. Stuttgart.
- Breiman, Leo. 1992. "OUT-OF-BAG ESTIMATION." Berkeley.
- . 1996. "Bagging predictors." *Machine Learning* 24 (2): 123-40. doi: 10.1007/bf00058655.
- . 2001. "Random Forests." *Machine Learning* 45 (1): 5-32. doi: 10.1023/a:1010933404324.
- Breiman, Leo, Adele Cutler, Andy Liaw, und Matthew Wiener. 2018. "Breiman and Cutler's Random Forests for Classification and Regression." Zugriff am 17.04.2018. <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>.
- Chittum, Anna, und Poul Alberg Østergaard. 2014. "How Danish communal heat planning empowers municipalities and benefits individual consumers." *Energy Policy* 74: 465-74. doi: <https://doi.org/10.1016/j.enpol.2014.08.001>.
- Clevers, J. G. P. W., und Anatoly Gitelson. 2012. *Using the red-edge bands on Sentinel-2 for retrieving canopy chlorophyll and nitrogen content*. Vol. 707.
- Congalton, Russell G. 1991. "A review of assessing the accuracy of classifications of remotely sensed data." *Remote Sensing of Environment* 37 (1): 35-46. doi: [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).

- Diefenbach, Nikolaus. 2013. "Basisdaten für Hochrechnungen mit der Deutschen Gebäudetypologie des IWU." Darmstadt: IWU.
- Drusch, M., U. Del Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, et al. 2012. "Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services." *Remote Sensing of Environment* 120: 25-36. doi: <https://doi.org/10.1016/j.rse.2011.11.026>.
- Eicker, Ursula, Romain Nouvel, Claudia Schulte, Jürgen Schumacher, und Volker Coors. 2012. "3D-STADTMODELLE FÜR DIE WÄRMEBEDARFBERECHNUNG." *Fourth German-Austrian IBPSA Conference*. Berlin University of the Arts.
- Danish Energy Agency. 2017. Regulation and planning of district heating in Denmark, Copenhagen.
- ESA. 2012. "Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services." Noordwijk: ESA Communications.
- . 2015. "Sentinel-2 User Handbook." 64. European Space Agency (ESA).
- FVEE. 2015. Forschung für die Wärmewende. Paper präsentiert bei FVEE-Jahrestagung 2015, Berlin.
- Geiß, C., H. Taubenb, M. Wurm, T. Esch, M. Nast, C. Schillings, und T. Blaschke. 2011. "Remote Sensing-Based Characterization of Settlement Structures for Assessing Local Potential of District Heat." *Remote Sensing* 3 (7): 1447 - 71.
- Gislason, Pall Oskar, Jon Atli Benediktsson, und Johannes R. Sveinsson. 2006. "Random Forests for land cover classification." *Pattern Recognition Letters* 27 (4): 294-300. doi: <https://doi.org/10.1016/j.patrec.2005.08.011>.
- Gochermann, Josef. 2016. "Regional – kommunal – individual." In *Expedition Energiewende*(Hrsg.), 219-50. Wiesbaden: Springer Fachmedien Wiesbaden.
- Gültlinger, Manfred. 2018. "3D - Gebäudemodelle." Landesamt für Geoinformation und Landentwicklung, Zugriff am 10.04.2018. https://www.lgl-bw.de/lgl-internet/web/sites/default/de/01_Aktuelles/Veranstaltungen/Galerien/Dokumente/3D_LOD2_Info_LGL.pdf.
- Haralick, R. M. 1979. "Statistical and structural approaches to texture." *Proceedings of the IEEE* 67 (5): 786-804. doi: 10.1109/PROC.1979.11328.
- Haralick, R. M., K. Shanmugam, und I. Dinstein. 1973. "Textural Features for Image Classification." *IEEE Transactions on Systems, Man, and Cybernetics* SMC-3 (6): 610-21. doi: 10.1109/TSMC.1973.4309314.
- Hecht, Robert. 2014. "Automatische Klassifizierung von Gebäudegrundrissen : ein Beitrag zur kleinräumigen Beschreibung der Siedlungsstruktur." phd thesis, Rhombos-Verl.

- Irons, James R., und Gary W. Petersen. 1981. "Texture transforms of remote sensing data." *Remote Sensing of Environment* 11: 359-70. doi: [https://doi.org/10.1016/0034-4257\(81\)90033-X](https://doi.org/10.1016/0034-4257(81)90033-X).
- Keil, Manfred, Michael Bock, Thomas Esch, Annekatri Metz, Simon Nieland, und Alexander Pfitzner. 2011. "CORINE Land Cover." *Aktualisierung 2006 für Deutschland*, 67. Dessau-Roßlau: Umweltbundesamt.
- Keil, Manfred, Thomas Esch, Andreas Divanis, Mattia Marconcini, Annekatri Metz, Marco Ottinger, Sergey Voinov, Michael Wiesner, Michael Wurm, und Julian Zeidler. 2015. "Aktualisierung der Landnutzungs- und Landbedeckungsdaten CLC für das Jahr 2012-"Backdating" des DLM-DE vom Referenzjahr 2009 zurück auf das Jahr 2006." 84. Dessau-Roßlau: Umweltbundesamt.
- Kelm, Tobias, Antje Vogel-Sperl, Maike Schmidt, Michael Capota, Evelyn Sperber, und Christof Husenbeth. 2014. "Studie Landeskonzept Kraft-Wärme-Kopplung Baden-Württemberg."
- Kuhn, Max. 2008. "Building Predictive Models in R Using the caret Package." 2008 28 (5): 26. doi: 10.18637/jss.v028.i05.
- Kulkarni, Arun D. , und Barrett Lowe. 2016. "Random Forest Algorithm for Land Cover Classification." *Computer Science Faculty Publications and Presentations* Paper 1.
- Langanke, Tobias. 2013. "GIO land (GMES/Copernicus initial operations land) High Resolution Layers (HRLs) - summary of product specifications." 15. European Environment Agency.
- LDBV. 2017. "Datenformatbeschreibung 3D-Gebäudemodell LoD1 Deutschland (LoD1-DE)." 5. Landesamt für Digitalisierung, Breitband und Vermessung.
- Leutner, Benjamin, und Ned Horning. 2018. "RStoolbox." github.com, Zugriff am 14.04.2018. <https://bleutner.github.io/RStoolbox/>.
- Loga, Tobias, Britta Stein, Nikolaus Diefenbach, und Rolf Born. 2015. "Deutsche Wohngebäudetypologie. Zweite erweiterte Auflage." 281. Darmstadt: IWU.
- Lu, Dengsheng. 2006. *The Potential and Challenge of Remote Sensing-Based Biomass Estimation*. Vol. 27.
- Maier, Magnus. 2016. "Die kommunale Wärmeplanung." *RENEWS SPEZIAL* 79: 28.
- Malenovský, Zbyněk, Helmut Rott, Josef Cihlar, Michael E. Schaepman, Glenda García-Santos, Richard Fernandes, und Michael Berger. 2012. "Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of ocean, cryosphere, and land." *Remote Sensing of Environment* 120: 91-101. doi: <https://doi.org/10.1016/j.rse.2011.09.026>.
- Müller-Wilm, Uwe, O Devignot, und Pessiot. 2017. "S2 MPC - Sen2Cor Configuration and User Manual." (2.4): 53.

- Nitsch, Joachim. 2008. "Weiterentwicklung der "Ausbaustrategie erneuerbare Energie" vor dem Hintergrund der aktuellen Klimaschutzziele Deutschlands und Europa." 191. Stuttgart: BMU.
- Nouvel, Romain, Alessio Mastrucci, Ulrich Leopold, Olivier Baume, Volker Coors, und Ursula Eicker. 2015. "Combining GIS-based statistical and engineering urban heat consumption models: Towards a new framework for multi-scale policy support." *Energy and Buildings* 107: 204-12. doi: <https://doi.org/10.1016/j.enbuild.2015.08.021>.
- Nouvel, Romain, Claudia Schulte, Ursula Eicker, Dirk Pietruschka, und Volker Coors. 2013. "CITYGML-BASED 3D CITY MODEL FOR ENERGY DIAGNOSTICS AND URBAN ENERGY POLICY SUPPORT." *13th Conference of International Building Performance Simulation Association*. Chambéry, France.
- Orth, Ann-Sophie. 2016. "Kommunale Wärmeplanung." Hafencity Universität Hamburg.
- Pesaresi, Martino, Christina Corbane, Andreea Julea, Aneta Florczyk, Vasileios Syrris, und Pierre Soille. 2016. "Assessment of the Added-Value of Sentinel-2 for Detecting Built-up Areas." *Remote Sensing* 8 (4): 299.
- Radoux, Julien, Guillaume Chomé, Damien Jacques, François Waldner, Nicolas Bellemans, Nicolas Matton, Céline Lamarche, Raphaël d'Andrimont, und Pierre Defourny. 2016. "Sentinel-2's Potential for Sub-Pixel Landscape Feature Detection." *Remote Sensing* 8 (6): 488.
- Schubert, Susanne. 2016. "Ausbau von Wärmenetzen vs. energetische Sanierung? – Umgang mit konkurrierenden Strategien zur Umsetzung der „Wärmewende“ auf kommunaler Ebene." *Raumforschung und Raumordnung* 74 (3): 259-71. doi: 10.1007/s13147-016-0393-8.
- Energy & Climate Change Directorate. 2015. Scotland Heat Map - User guide. Methodology report, The Scottish Government. Edinburgh.
- Sen, Avery. 2004. *The benefits of remote sensing for energy policy*. Vol. 20.
- SH-MLUR. 2014. Die kommunale Wärmeplanung, Ministerium für Energiewende, Landwirtschaft, Umwelt und ländliche Räume. Kiel.
- Stehman, S. V. 1995. "Thematic map accuracy assessment from the perspective of finite population sampling." *International Journal of Remote Sensing* 16 (3): 589-93. doi: 10.1080/01431169508954425.
- Stehman, Stephen V. 1997. "Selecting and interpreting measures of thematic classification accuracy." *Remote Sensing of Environment* 62 (1): 77-89. doi: [https://doi.org/10.1016/S0034-4257\(97\)00083-7](https://doi.org/10.1016/S0034-4257(97)00083-7).
- TOPALOĞLU, Raziye Hale, Elif Sertel, und Nebiye MUSAOĞLU. 2016. "ASSESSMENT OF CLASSIFICATION ACCURACIES OF SENTINEL-2 AND LANDSAT-8 DATA FOR LAND COVER/USE MAPPING." *International*

- Klima und Energiewirtschaft Baden-Württemberg Ministerium für Umwelt. 2014. Integriertes Energie- und Klimaschutzkonzept Baden - Württemberg (IEKK), Stuttgart.
- USGS. 2016. "LANDSAT 8. DATA USERS HANDBOOK." 98.
- Walde, I., S. Hese, C. Berger, und C. Schmullius. 2013. "Graph-Based Mapping of Urban Structure Types From High-Resolution Satellite Image Objects; Case Study of the German Cities Rostock and Erfurt." *IEEE Geoscience and Remote Sensing Letters* 10 (4): 932-6. doi: 10.1109/LGRS.2013.2252323.
- Weng, Q. 2009. "Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends." *ISPRS Journal of Photogrammetry and Remote Sensing* 64 (4): 335-44. doi: <http://dx.doi.org/10.1016/j.isprsjprs.2009.03.007>.
- Weng, Q., und P. Fu. 2014. "Modeling annual parameters of clear-sky land surface temperature variations and evaluating the impact of cloud cover using time series of Landsat TIR data." *Remote Sensing of Environment* 140: 267-78. doi: <http://dx.doi.org/10.1016/j.rse.2013.09.002>.
- Wurm, M., A. Schmitt, und H. Taubenböck. 2016. "Building Types' Classification Using Shape-Based Features and Linear Discriminant Functions." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (5): 1901-12. doi: 10.1109/JSTARS.2015.2465131.
- Wurm, M., H. Taubenböck, A. Roth, und S. Dech. 2009. Urban structuring using multisensoral remote sensing data: By the example of the German cities Cologne and Dresden. Paper präsentiert bei 2009 Joint Urban Remote Sensing Event, 20-22 May 2009.
- Zheng, Hongrui, Peijun Du, Jike Chen, Junshi Xia, Erzhu Li, Zhigang Xu, Xiaojuan Li, und Naoto Yokoya. 2017. "Performance Evaluation of Downscaling Sentinel-2 Imagery for Land Use and Land Cover Classification by Spectral-Spatial Features." *Remote Sensing* 9 (12): 1274.

Anhang

A1 – Detaillierte Beschreibung der weiteren Varianten zur Klassifikation der Landbedeckung

Die folgenden Absätze dienen der weitergehenden Beschreibung der einzelnen Klassifikationsvarianten im Rahmen der Landbedeckungsklassifikation. Explizit wird hier auf die erzielte Genauigkeit pro Klasse eingegangen, um ein erweitertes Verständnis des Einflusses der verschiedenen Varianten auf die erzielte Genauigkeit zu ermöglichen.

Tabelle A1 – 1: Konfusionsmatrix der Variante 1

		Refe- renz							
		11	12	13	21	22	31	32	40
Klassi- fiziert	11	956	654	2	12	0	3	1	0
	12	1	358	0	0	0	1	0	0
	13	0	0	436	224	0	7	0	0
	21	51	0	530	828	0	4	0	0
	22	0	0	0	0	1022	8	8	0
	31	0	0	44	22	31	890	144	0
	32	0	0	0	0	0	116	859	0
	40	0	0	0	0	0	0	1	468

Mit Verweis auf Tabelle A1 - 1 können die einzelnen Klassen konkret analysiert werden. So fallen für die Klassen 12 und 13 massive Fehlzuweisungen auf. Dabei erstrecken sich die Fehler größtenteils auf die Unterschätzung der beiden Klassen: wurden 358 Samples korrekterweise Klasse 12 zugeordnet, so gingen 654 an die Klasse 11. Ähnliches lässt sich bei Klasse 13 feststellen: bei 436 korrekt klassifizierten Samples wurden 530 der Klasse 21 zugewiesen. Vergleichbare Größenordnungen können bei keiner anderen Klasse gefunden werden. Zwischen den Klassen 31 und 32 scheint es jedoch ebenfalls einige Samples zu geben, welche nicht korrekt getrennt werden können. Gleiches gilt für die Klassen 11 und 21. Lediglich Klasse 40 fällt dahingehend auf, dass hier nur eine Überschätzung aufgrund eines einzigen Samples zu verzeichnen ist.

Für Tabelle A1 - 2 zeigt sich ein leicht verändertes Bild. Über alle Klassen hinweg können im Vergleich zu Tabelle 8 erhöhte Anzahlen der jeweils korrekt klassifizierten Samples vermerkt werden. Dies macht sich insbesondere bei den Klassen 12, 13, 31 und 32 bemerkbar. Jedoch gilt auch weiterhin, dass die Klassen 12 und 13 mit Abstand

am schlechtesten abschneiden, da beide von erheblichen Unterschätzungen betroffen sind. Einher geht dies mit der analogen erheblichen Überschätzung der Klassen 11, bzw. 21.

Tabelle A1 – 2: Konfusionsmatrix der Variante 2

		Referenz							
		11	12	13	21	22	31	32	40
Klassifiziert	11	971	629	0	3	0	0	0	0
	12	4	375	0	0	0	0	0	0
	13	0	0	538	207	0	1	0	0
	21	33	4	471	875	0	0	0	0
	22	0	0	0	0	1051	0	4	0
	31	0	0	1	0	2	952	61	0
	32	0	4	2	1	0	76	946	0
	40	0	0	0	0	0	0	2	468

Tabelle A1 – 3: Konfusionsmatrix der Variante 3

		Referenz					
		11	21	22	31	32	40
Klassifiziert	11	996	11	0	1	0	0
	21	25	1065	0	3	0	0
	22	0	0	1036	8	12	0
	31	0	18	16	918	146	0
	32	0	0	1	99	854	0
	40	0	0	0	0	1	468

Wurden nun die Klassen 11 und 12, bzw. 13 und 21 zusammengelegt, so ergibt dies das Bild in Tabelle A1 - 3. Markant ist hier, dass sich mit der gesteigerten Grundgesamtheit der beiden genannten Klassen die relativen Verhältnisse im Vergleich zu Tabelle 8 kaum geändert haben. Unter- bzw. Überschätzung gibt es vor allem bei den Klassen 21 und 11, sowie zwischen den Klassen 31 und 32. Auch auffällig sind jene 16 Samples, welche fälschlicherweise der Klasse 31 zugeordnet wurden, eigentlich jedoch Klasse 22 angehören. Andererseits fällt die umgekehrte Unterschätzung der Klasse 31 deutlich geringer aus, im Wesentlichen zugunsten von Klasse 32. Betrachtet man Tabelle A1 – 4, so können die größten Raten an Überschätzung den Klassen 32,

31 und 21 zugesprochen werden. Hier fällt besonders der Wert von 246 auf, welcher gleichzeitig einer Unterschätzung der Klasse 31 entspricht.

Tabelle A1 – 4: Konfusionsmatrix der Variante 5

		Referenz					
Klassifi- ziert		11	21	22	31	32	40
	11	2024	8	0	0	0	0
	21	3	2078	40	51	16	0
	22	0	0	2022	0	2	0
	31	0	0	2	1763	27	0
	32	0	1	1	246	1979	0
	40	0	0	0	2	5	916

Gleiches gilt für die Klassen 21 und 22, wobei hier die absoluten Werte deutlich niedriger ausfallen. Anzumerken ist für die Klasse 21, dass ebenfalls etliche Samples der Klassen 31 und 32 klassifiziert wurden. Hingegen ist eine klare Differenzierung zwischen den Klassen 22 und 31, sowie 22 und 32 ersichtlich. Ebenso scheint die Klasse 11 klar von sämtlichen weiteren Klassen differenzierbar zu sein. Mit Abstand die geringste Raten an Über- und Unterschätzung weist abermals Klasse 40 auf.

Tabelle A1 – 5: Konfusionsmatrix der Variante 6

		Referenz					
Klassifi- ziert		11	21	22	31	32	40
	11	1228	906	11	229	103	209
	21	515	904	404	1036	483	1492
	22	3	15	1228	15	8	24
	31	348	571	292	468	1143	73
	32	129	223	67	318	353	58
	40	454	114	36	68	49	178

Ein gänzlich anderes Bild zeichnet sich mit Blick auf Tabelle A1 - 5 ab. Hier scheint keinerlei eindeutige Differenzierung zwischen den Klassen möglich zu sein. Dennoch gibt es auch hier, im absoluten Wertebereich, deutliche Unterschiede zwischen den Klassen. Die höchsten absoluten Werte weisen die Klassen 21 und 31 auf. So wird Klasse 21 zulasten von den Klassen 31 und 40 sehr stark überschätzt – immerhin knapp 1500 Samples von Klasse 40 wurden fälschlicherweise der Klasse 21 zugewiesen. Nahezu die gleiche Anzahl stammt von der Klasse 31. Im Falle der Klasse 31 fällt

der Wert von rund 1150 auf. Hier scheint eine Trennung zwischen den Klassen 31 und 32 kaum möglich.

Das Bild, das sich mit Blick auf Tabelle A1 - 6 abzeichnet, unterscheidet sich teilweise von dem im Vorfeld gezeichneten. Eine markante Ausnahme bildet hierbei Klasse 22. Lediglich eine geringe Überschätzung mit Blick auf Klasse 21 (25), sowie eine geringfügige Unterschätzung mit Blick auf Klasse 32 (74) ist hier zu vermerken.

Tabelle A1 – 6: Konfusionsmatrix der Variante 7

		Referenz					
		11	21	22	31	32	40
Klassifiziert	11	1559	1281	0	415	7	2
	21	95	368	9	310	343	9
	22	1	25	1962	7	5	0
	31	235	150	0	848	783	8
	32	119	77	74	432	858	24
	40	3	150	0	8	20	405

Klasse 21 stellt hierfür den Counterpart dar – hier wurde zugunsten von Klasse 11 massiv unterschätzt (1281). Ebenfalls 150 Samples wurden jeweils den Klassen 31 und 40 zugerechnet. Auf der anderen Seite ist eine markante Überschätzung von Klasse 21 zu Lasten von Klasse 31 (310) und Klasse 32 (343) zu verzeichnen. Eine ebenfalls erhebliche Überschätzung ist bezüglich Klasse 11 festzuhalten: Immerhin 1281 Samples wurden zu Lasten von Klasse 21 klassifiziert, ebenso 415 Samples zu Lasten von Klasse 31. Hinsichtlich Klasse 40 ist zu erwähnen, dass diese zwar vergleichsweise gut wiedergegeben wird, aber dennoch einige Probleme bezüglich der Differenzierung zwischen Klasse 21 und 40 zu bestehen scheinen. So können 150 Samples der Klasse 21 der Überschätzung von Klasse 40 zugeschrieben werden.

Im Vergleich zu den vorhergehenden Matrizen sind die Differenzierungen in Tabelle A1 - 7 zwischen den Klassen wesentlich deutlicher ausgeprägt. Jedoch gibt es auch hier einige Ausreißer: so wurde Klasse 31 um 241 Samples zugunsten der Klasse 32 unterschätzt. Gleichsam besteht für Klasse 32 eine Überschätzung von 241 Samples, welche entsprechend der Referenz zur Klasse 31 gehören. Weitere Fehler sind zwischen den Klassen 21 und 22, sowie zwischen 21 und 11 zu finden. Auffällig ist weiterhin, dass fast jede Klasse eine Überschätzung von Klasse 40 beinhalten.

Tabelle A1 – 7: Konfusionsmatrix der Variante 8

		Referenz					
		11	21	22	31	32	40
Klassifi- ziert	11	1998	2	0	0	1	0
	21	13	2032	19	1	0	0
	22	0	0	2011	0	5	0
	31	0	1	1	1784	39	0
	32	0	0	2	241	1967	0
	40	11	6	0	4	8	468

Für Variante 9 wird auf eine detaillierte Betrachtung der Konfusionsmatrix verzichtet, da sich ein ähnliches Bild wie in Tabelle A1 - 5 abzeichnet. Somit würde eine Betrachtung der Konfusionsmatrix keinen Mehrwert hinsichtlich der Information über die Fehlerverteilung der einzelnen Klassen liefern. Es soll jedoch an dieser Stelle festgehalten werden, dass es auch für diese Variation nicht möglich war, die Fehler explizit einzelnen Klassen zuzuweisen. Vielmehr scheint diese Konstellation an Eingangsdaten nicht geeignet, die vorliegende Szene hinsichtlich des gegebenen Klassenschemas zu differenzieren.

A2 – Darstellungen der Gebäudeanzahl je Gebäudetyp pro Verwaltungsebene

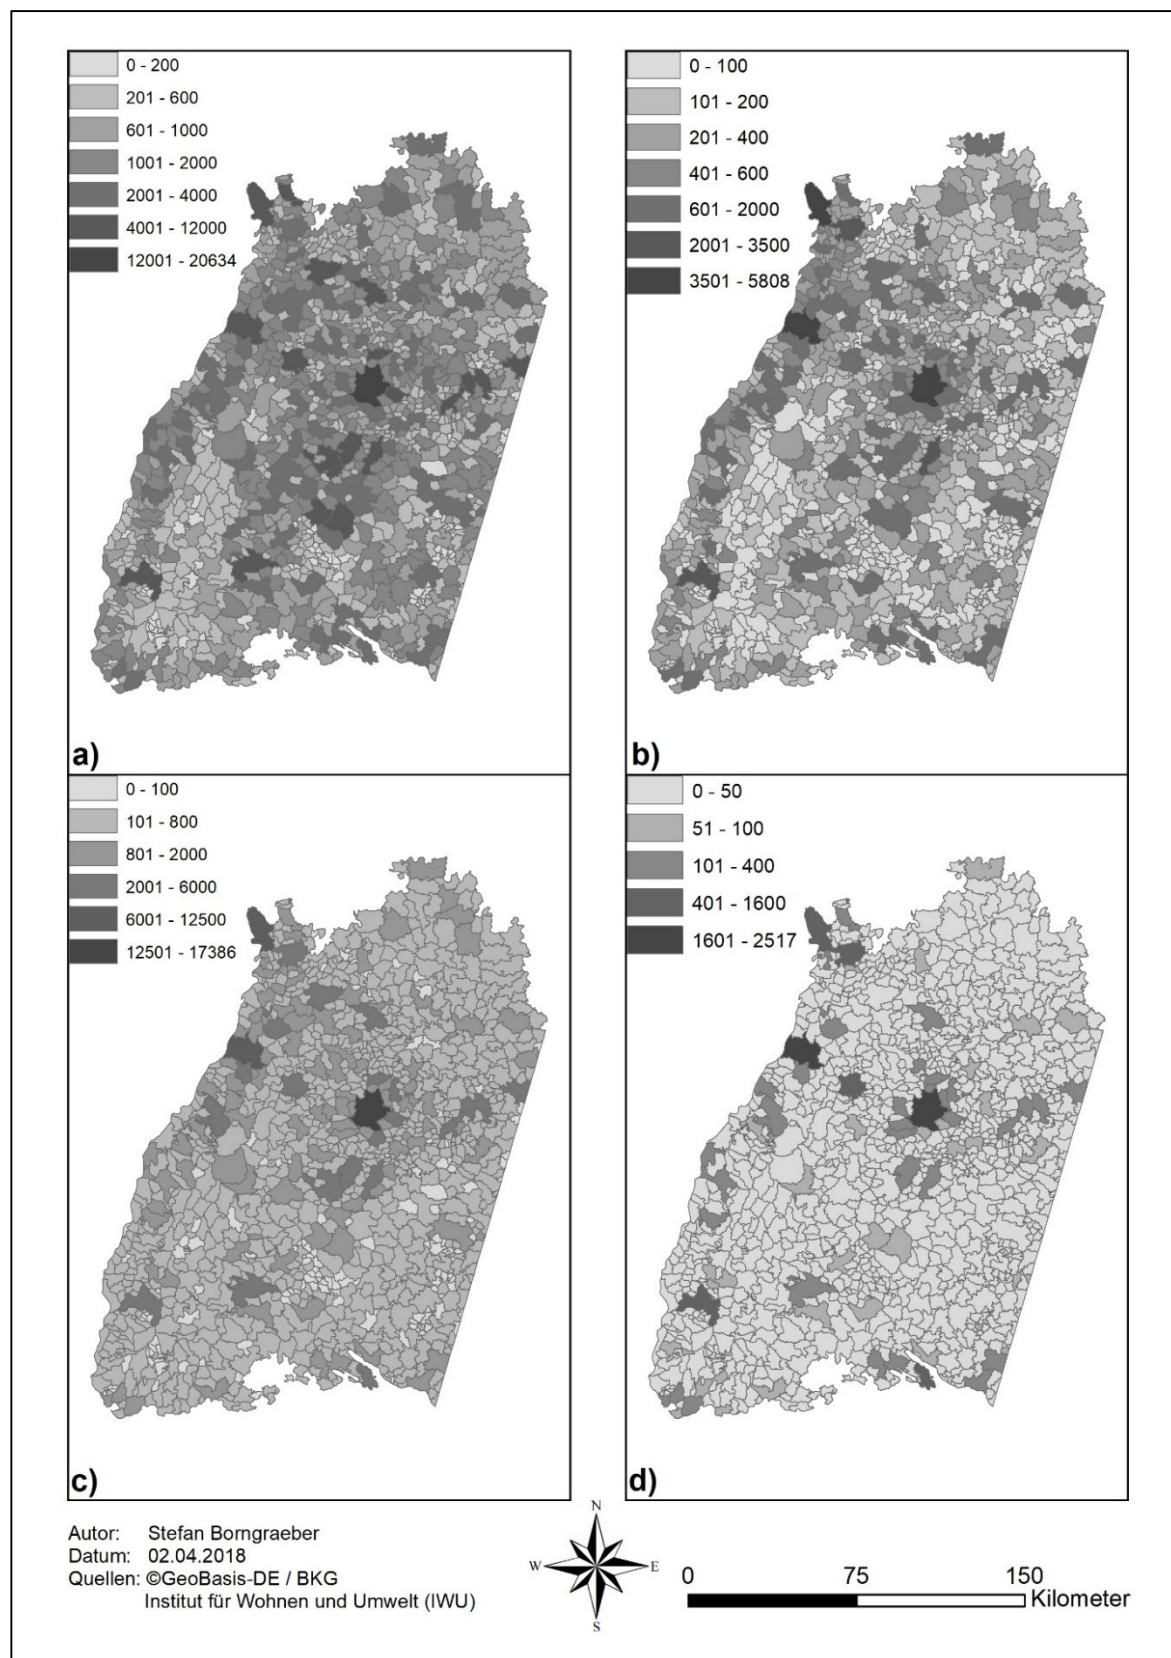


Abbildung A2-1: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene in Baden – Württemberg; Räumliche Verteilungsmuster; a) EFH, b) RH, c) MFH, d) AB

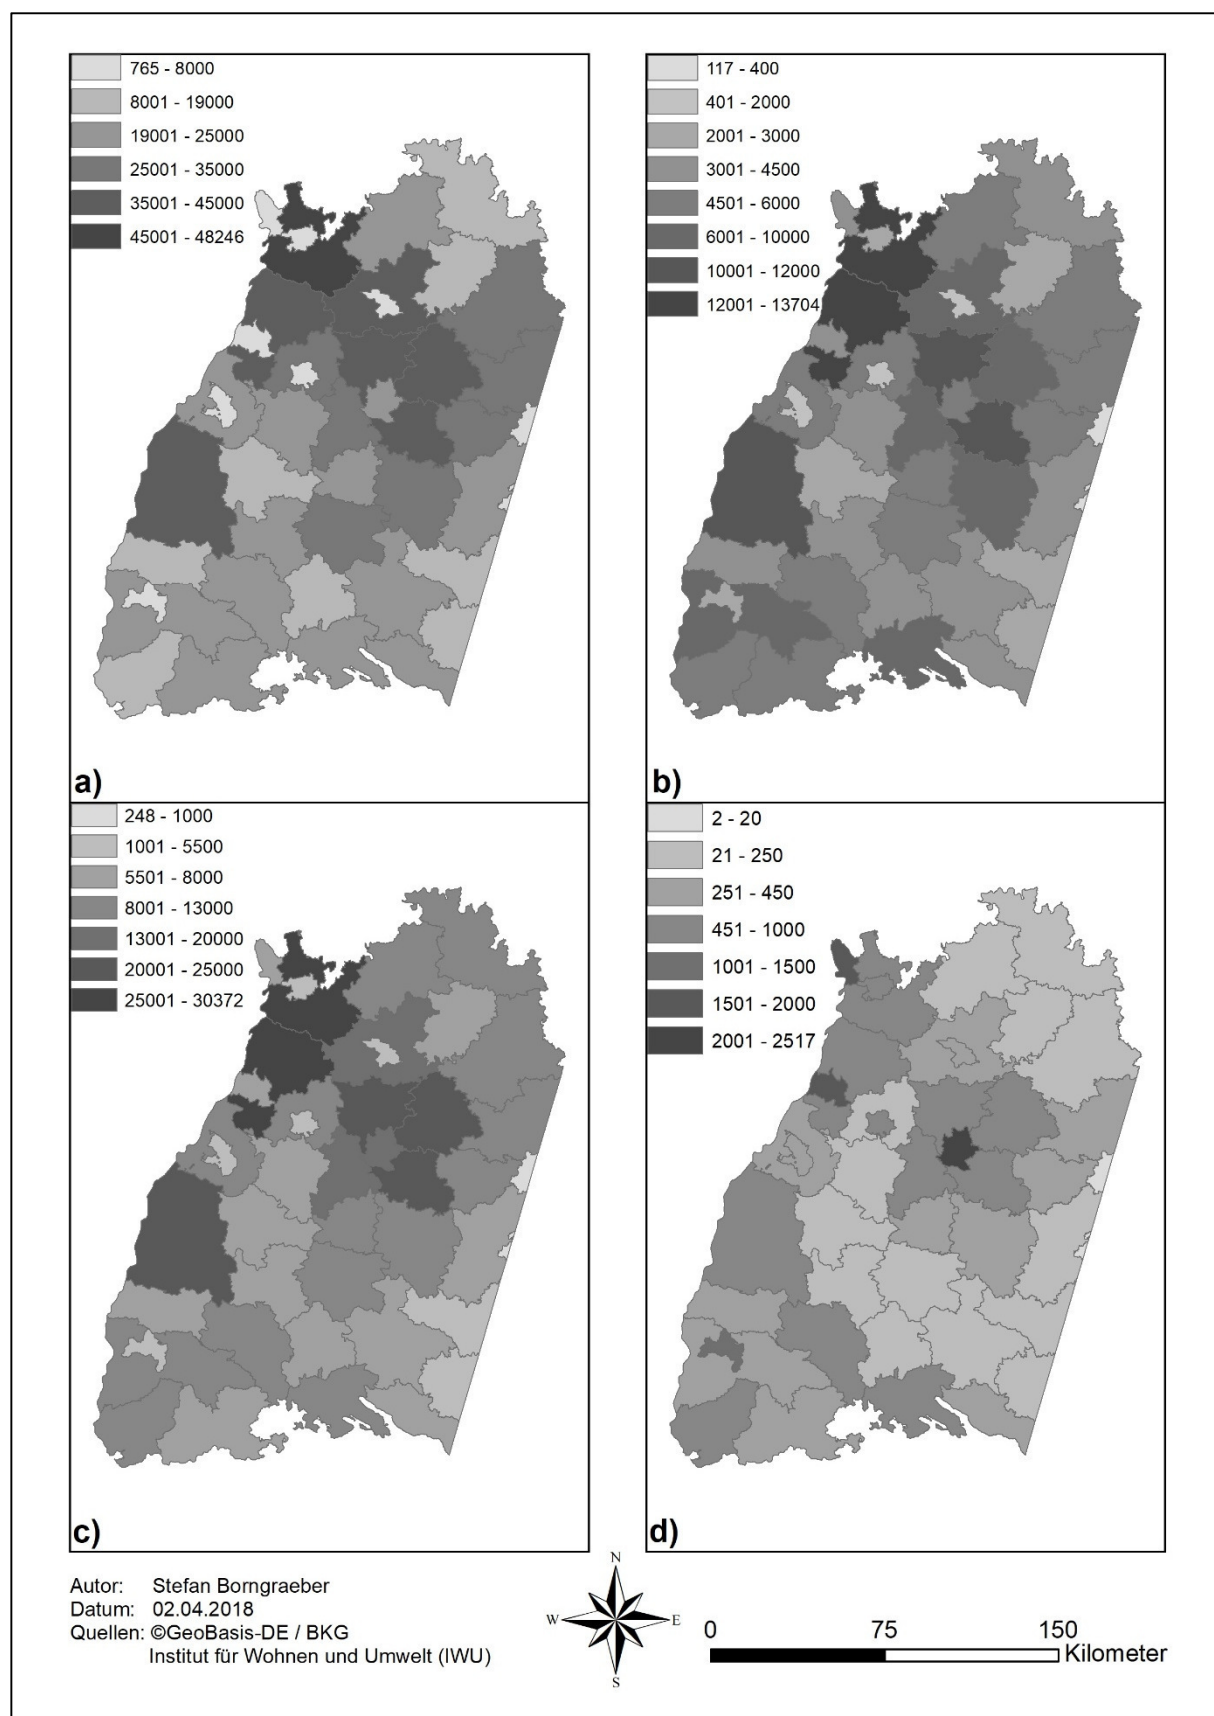


Abbildung A2-2: Gebäudeanzahl je Gebäudegröße auf Landkreisebene in Baden – Württemberg; Räumliche Verteilungsmuster; a) EFH, b) RH, c) MFH, d) AB

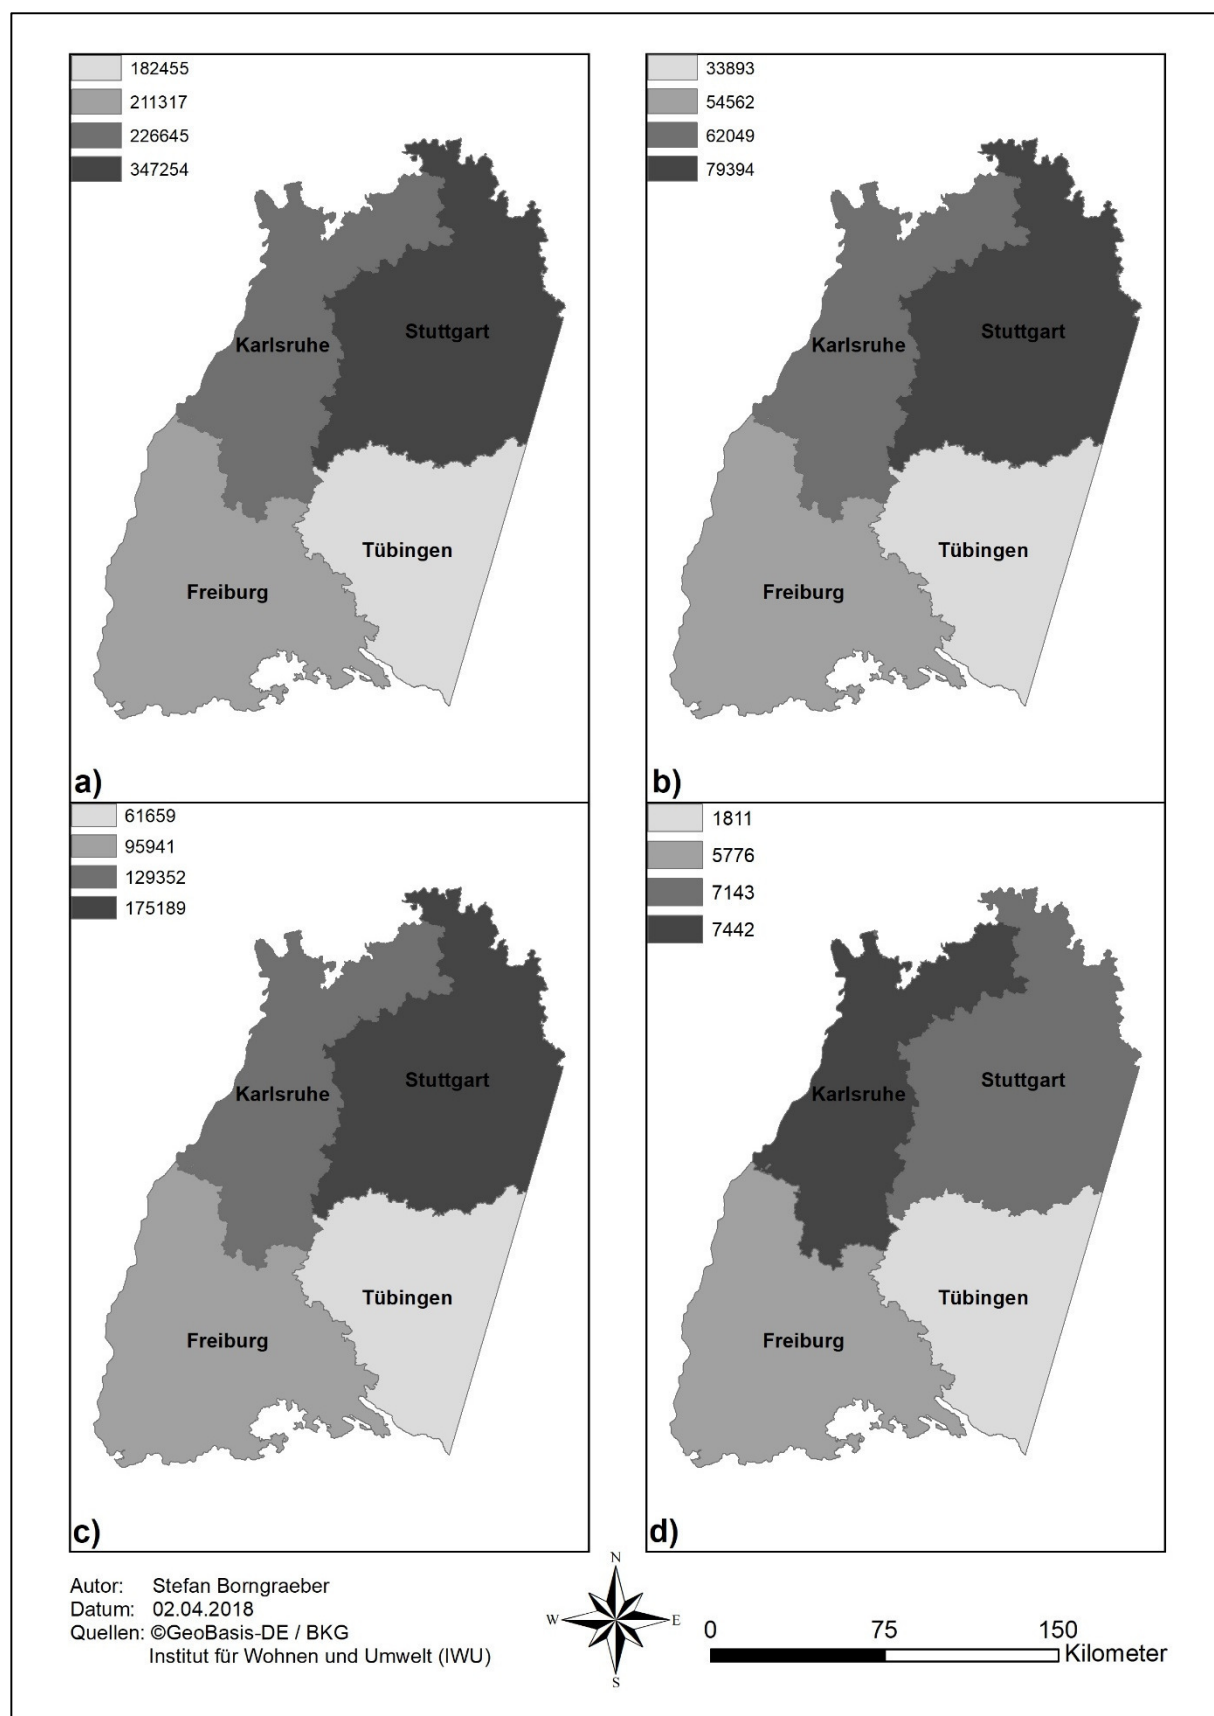


Abbildung A2-3: Gebäudeanzahl je Gebäudegröße auf Regierungsbezirksebene in Baden – Württemberg; Räumliche Verteilungsmuster; a) EFH, b) RH, c) MFH, d) AB




Abbildung A2-4: Gebäudeanzahl je Gebäudegröße auf Gemeindeebene




Abbildung A2-5: Gebäudeanzahl je Gebäudegröße auf Landkreisebene




Abbildung A2-6: Gebäudeanzahl je Gebäudegröße auf Regierungsbezirksebene

Mit Blick auf die Tabellen A3 – 1 bis 4 muss angemerkt werden, dass im Falle der grau hinterlegten Felder keine Daten vorhanden waren. Entsprechend wurde die Anzahl der Bestandsgebäude der vorhergehenden Altersklasse angenommen. Die rot eingefärbten Linien repräsentieren die in dieser Arbeit gewählten Baualtersklassen.

Klasse	Sub - Klasse (TABULA)	Mod - Paket	EFH - Netto [kWh / m²a]	Mittelwert (EFH - Netto [kWh / m²a])	Anzahl Geb pro AK (Subklasse)	Summe (Anzahl pro Subklasse)	Gewichtung entspr. Anzahl Geb pro Subklasse	EFH - Netto gewichtet	EFH - Netto pro BAK [kWh / m²a]	EFH - Netto für EFH gesamt [kWh / m²a]		
1859 - 1957	...	1859	IST MP1 MP2	184 102 32	106,00	330000	3286000	0,10	10,65	106,73		
	1860 - 1918	IST MP1 MP2	181 105 42	109,33	966000	0,29 0,34 0,26		32,14 33,27 30,67	106,73			
	1919 - 1948	IST MP1 MP2	164 92 34	96,67	1131000							
	1949 - 1957	IST MP1 MP2	182 123 47	117,33	859000							
1958 - 1994	1958 - 1968	IST MP1 MP2	180 129 57	122,00	1509000						4880000	0,31
	1969 - 1978	IST MP1 MP2	153 99 43	98,33	1507000	0,31 0,14 0,24		30,37 11,06 22,03	101,18			
	1979 - 1983	IST MP1 MP2	120 82 28	76,67	704000							
	1984 - 1994	IST MP1 MP2	132 104 42	92,67	1160000							
1995 - 2017	1995 - 2001	IST MP1 MP2	110,5 97,6 39,6	82,57	1035000		3360000			0,31		25,43
	2002 - 2009	IST MP1 MP2	78,7 72,9 36,1	62,57	775000	0,23 0,23 0,23		14,43 11,83 10,38	62,08			
	2010 - 2015	IST MP1 MP2	82,7 47,8 23,4	51,30	775000							
	2016 - heute	IST MP1 MP2	70,8 40,8 23,4	45,00	775000							

Tabelle A3-2: Konzept zur Ableitung der Wärmebedarfswerte für RH

Klasse	Sub - Klasse (TABULA)	Mod - Paket	RH - Netto [kWh / m²a]	Mittelwert (RH - Netto) [kWh / m²a]	Anzahl Geb pro AK (Subklasse)	Summe (Anzahl pro Subklasse)	Gewichtung entspr. Anzahl Geb pro Subklasse	RH - Netto gewichtet	RH - Netto pro BAK [kWh / m²a]	RH - Netto für RH gesamt [kWh / m²a]
1859 - 1957	...1859	IST	-	-	148000	1797000	0,08	-	81,04	67,36
		MP1	-							
		MP2	-							
1860 - 1918	IST	155	97,33	492000	0,27		26,65			
	MP1	102								
	MP2	35								
1919 - 1948	IST	135	79,33	710000	0,40		31,34			
	MP1	77								
	MP2	26								
1949 - 1957	IST	152	92,67	447000	0,25		23,05			
	MP1	90								
	MP2	36								
1958 - 1994	1958 - 1968	IST	104	64,67	633000	2231000	0,28	18,35	71,90	67,36
		MP1	69							
		MP2	21							
1969 - 1978	IST	124	78,33	611000	0,27		21,45			
	MP1	81								
	MP2	30								
1979 - 1983	IST	124	84,67	335000	0,15		12,71			
	MP1	95								
	MP2	35								
1984 - 1994	IST	95	66,33	652000	0,29		19,39			
	MP1	79								
	MP2	25								
1995 - 2017	1995 - 2001	IST	78,8	56,67	619000	1771000	0,35	19,81	49,15	67,36
		MP1	70,6							
		MP2	20,6							
2002 - 2009	IST	70,3	57,23	384000	0,22		12,41			
	MP1	69,7								
	MP2	31,7								
2010 - 2015	IST	71,2	41,77	384000	0,22		9,06			
	MP1	36,3								
	MP2	17,8								
2016 - heute	IST	60,6	36,33	384000	0,22		7,88			
	MP1	30,6								
	MP2	17,8								

Tabelle A3-3: Konzept zur Ableitung der Wärmebedarfswerte für MFH

Klasse	Sub - Klasse (TABULA)	Mod - Paket	MFH - Netto [kWh / m²a]	Mittelwert (MFH - Netto) [kWh / m²a]	Anzahl Geb pro AK (Subklasse)	Summe (Anzahl pro Subklasse)	Gewichtung entspr. Anzahl Geb pro Subklasse	MFH - Netto gewichtet	MFH - Netto pro BAK [kWh / m²a]	MFH - Netto für MFH gesamt [kWh / m²a]
1859 - 1957	...	1859	IST MP1 MP2	189 108 30	109,00	54000	1240000	0,04	4,75	90,81
		1860 - 1918	IST MP1 MP2	145 89 21	85,00	442000		0,36	30,30	
		1919 - 1948	IST MP1 MP2	166 91 29	95,33	388000		0,31	29,83	
		1949 - 1957	IST MP1 MP2	154 87 30	90,33	356000		0,29	25,93	
1958 - 1994		1958 - 1968	IST MP1 MP2	127 74 21	74,00	586000	1453000	0,40	29,84	75,42
		1969 - 1978	IST MP1 MP2	131 81 26	79,33	412000		0,28	22,50	
		1979 - 1983	IST MP1 MP2	115 75 23	71,00	146000		0,10	7,13	
		1984 - 1994	IST MP1 MP2	119 80 26	75,00	309000		0,21	15,95	
1995 - 2017		1995 - 2001	IST MP1 MP2	91,1 68,8 23,9	61,27	244000	499000	0,49	29,96	50,34
		2002 - 2009	IST MP1 MP2	58 54 20,9	44,30	85000		0,17	7,55	
		2010 - 2015	IST MP1 MP2	73,5 46,5 16,4	45,47	85000		0,17	7,74	
		2016 - heute	IST MP1 MP2	45,8 27,6 16,3	29,90	85000		0,17	5,09	

Tabelle A3-4: Konzept zur Ableitung der Wärmebedarfswerte für AB

Klasse	Sub - Klasse (TABULA)	Mod - Paket	AB - Netto [kWh / m²a]	Mittelwert (AB - Netto) [kWh / m²a]	Anzahl Geb pro AK (Subklasse)	Summe (Anzahl pro Subklasse)	Gewichtung entspr. Anzahl Geb pro Subklasse	AB - Netto gewichtet	AB - Netto pro BAK [kWh / m²a]	AB - Netto für AB gesamt [kWh / m²a]
1859 - 1957	...	1859	IST	-	-	600	0,01			
			MP1	-	-					
			MP2	-	-					
	1860 - 1918		IST	123	73,00	28700	0,53	38,80	75,57	
			MP1	79						
			MP2	17						
	1919 - 1948		IST	142	81,33	7400	0,14	11,15		
			MP1	78						
			MP2	24						
	1949 - 1957		IST	140	80,00	17300	0,32	25,63		
			MP1	77						
			MP2	23						
1958 - 1994	1958 - 1968		IST	129	73,67	34000	0,40	29,78		
			MP1	72						
			MP2	20						
	1969 - 1978		IST	115	67,00	50100	0,60	39,91		
			MP1	68						
			MP2	18						
	1979 - 1983		IST	-	-	15000	0,18	-		
			MP1	-						
			MP2	-						
	1984 - 1994		IST	-	-	28700	0,34	-		
			MP1	-						
			MP2	-						
1995 - 2017	1995 - 2001		IST	-	-	20900	0,48	-	69,70	
			MP1	-						
			MP2	-						
	2002 - 2009		IST	-	-	7600	0,17	-		
			MP1	-						
			MP2	-						
	2010 - 2015		IST	-	-	7600	0,17	-		
			MP1	-						
			MP2	-						
	2016 - heute		IST	-	-	7600	0,17	-		
			MP1	-						
			MP2	-						